

# Vorlesung Fehlerrechnung & Datenanalyse

Olaf Kaczmarek & Udo Werner

Heutiges Thema:

Daten,  $\chi^2$ -Fits, verschiedene Skalen

- Methode der kleinsten Quadrate  $\rightarrow$  Ausgleichsgraden,  $\chi^2$ -Fits
- Linearisierung von Daten
- Transformation von Daten und Fehlerfortpflanzung
- Logarithmische Skalen

# Methode der kleinsten Quadrate

## Gegeben seien:

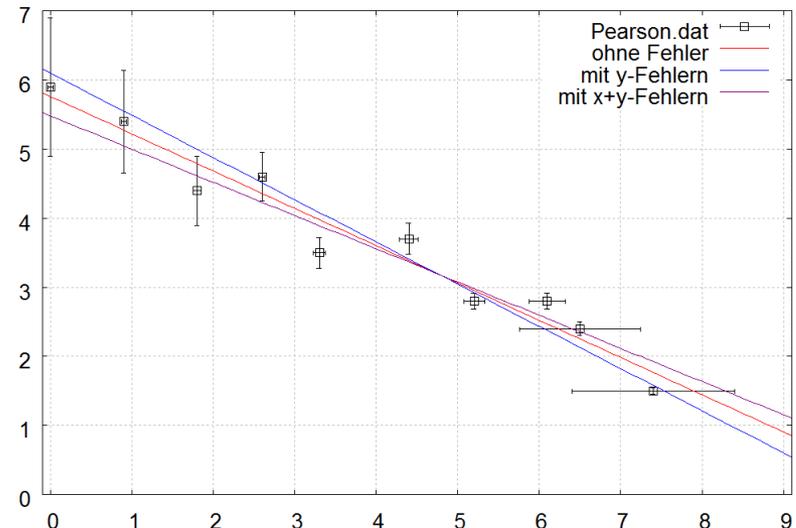
- Ein Satz von genau bekannten x-Werten  $\{x_i\}$
- Ein Satz von gemessenen y-Werten  $\{y_i\}$  mit Unsicherheiten  $\{\sigma_i\}$
- Eine von Parametern  $a=(a_1, \dots, a_k)$  abhängige Funktion  $f(x;a)$ , die die y-Werte vorhersagt

## Ziel:

- Die Parameter  $a_k$  so zu bestimmen, dass die Funktion  $f(x;a)$  den Datensatz möglichst gut beschreibt!

## Gütekriterium:

$$\chi^2 = \sum_i \left( \frac{y_i - f(x_i; \mathbf{a})}{\sigma_i} \right)^2$$



# Methode der kleinsten Quadrate

Gütekriterium:

$$\chi^2 = \sum_i \left( \frac{y_i - f(x_i; \mathbf{a})}{\sigma_i} \right)^2$$

minimiere  $\chi^2 \rightarrow$  Gute Approximation ("Fit")

notwendige Bedingung:  $\frac{\partial \chi^2}{\partial a_j} = 0 \quad j = 1, \dots, k$

$\rightarrow$  Gleichungssystem für Bestimmung der  $a_j$ :

$$\sum_i \frac{1}{\sigma_i^2} \frac{\partial f(x_i; a)}{\partial a_j} (y_i - f(x_i; a)) = 0 \quad j = 1, \dots, k$$

# Least squares fit: $y = m x + b$

Messpunkte  $(x_1, y_1 \pm \sigma_y), \dots (x_N, y_N \pm \sigma_y)$  d.h. zunächst konstante Fehler  $\sigma_i = \sigma_y$

Minimiere 
$$\chi^2 = \sum_{i=1}^N \frac{(y_i - mx_i - b)^2}{\sigma_y^2}$$

Notwendige Bedingung

$$0 = \frac{\partial \chi^2}{\partial b} = \left( \frac{-2}{\sigma_y^2} \right) \sum_{i=1}^N (y_i - mx_i - b)$$

$$0 = \frac{\partial \chi^2}{\partial m} = \left( \frac{-2}{\sigma_y^2} \right) \sum_{i=1}^N x_i (y_i - mx_i - b)$$

$$\begin{aligned} \Rightarrow \sum y_i &= Nb + m \sum x_i & \Rightarrow b &= \frac{(\sum x_i^2)(\sum y_i) - (\sum x_i)(\sum x_i y_i)}{N \sum x_i^2 - (\sum x_i)^2} \\ \sum x_i y_i &= b \sum x_i + m \sum x_i^2 & \Rightarrow m &= \frac{N(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{N \sum x_i^2 - (\sum x_i)^2} \end{aligned}$$

# Least squares fit: $y = m x + b$

Messpunkte  $(x_1, y_1 \pm \sigma_y), \dots (x_N, y_N \pm \sigma_y)$  d.h. zunächst konstante Fehler  $\sigma_i = \sigma_y$

Minimiere

$$\chi^2 = \sum_{i=1}^N \frac{(y_i - mx_i - b)^2}{\sigma_y^2}$$

Lösung:

$$\hat{m} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\overline{x^2} - \bar{x}^2}$$

$$\hat{b} = \bar{y} - \hat{m}\bar{x}$$

Fehler:

$$\sigma_m^2 = \frac{\sigma^2}{N(\overline{x^2} - \bar{x}^2)}$$

$$\sigma_b^2 = \frac{\sigma^2 \bar{x}^2}{N(\overline{x^2} - \bar{x}^2)}$$

# Least squares fit: $y = m x + b$

Messpunkte  $(x_1, y_1 \pm \sigma_1), \dots (x_N, y_N \pm \sigma_N)$

Minimiere 
$$\chi^2 = \sum_{i=1}^N \frac{(y_i - mx_i - b)^2}{\sigma_i^2}$$

bei Verwendung der gewichteten Mittelwerte:

$$\bar{y} = \frac{\sum y_i / \sigma_i^2}{\sum 1 / \sigma_i^2} \quad \text{und} \quad \sigma^2 := \frac{\sum \sigma_i^2 / \sigma_i^2}{\sum 1 / \sigma_i^2} = \frac{N}{\sum 1 / \sigma_i^2}$$

gilt wieder:

$$\hat{m} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\overline{x^2} - \bar{x}^2}$$

$$\hat{b} = \bar{y} - \hat{m}\bar{x}$$

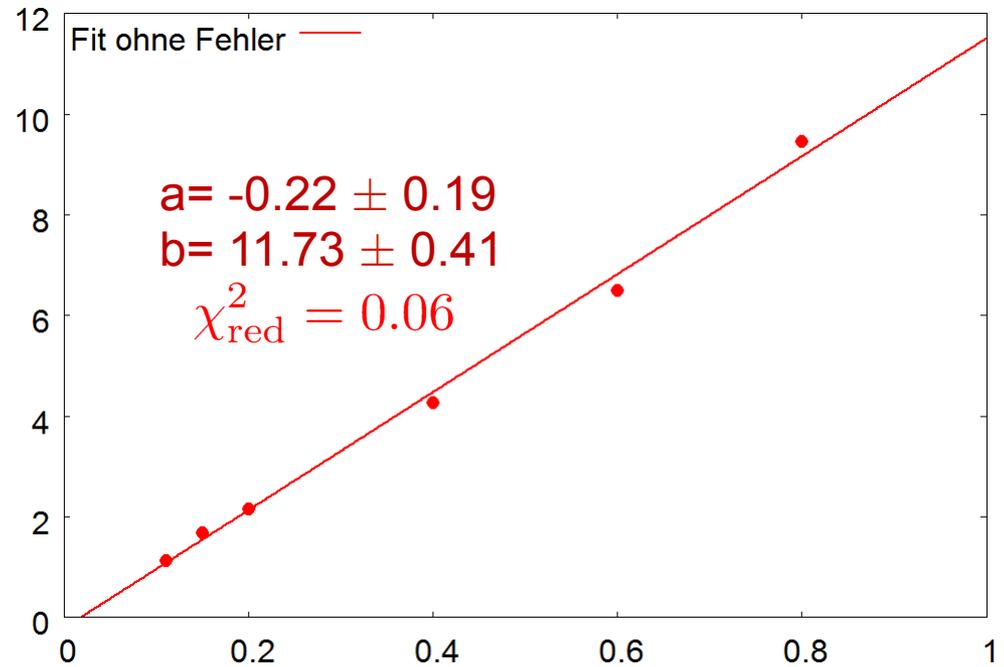
$$\sigma_m^2 = \frac{\sigma^2}{N(\overline{x^2} - \bar{x}^2)}$$

$$\sigma_b^2 = \frac{\sigma^2 \bar{x}^2}{N(\overline{x^2} - \bar{x}^2)}$$

# Linearer Fit

Ohne Berücksichtigung der  
Unsicherheiten:

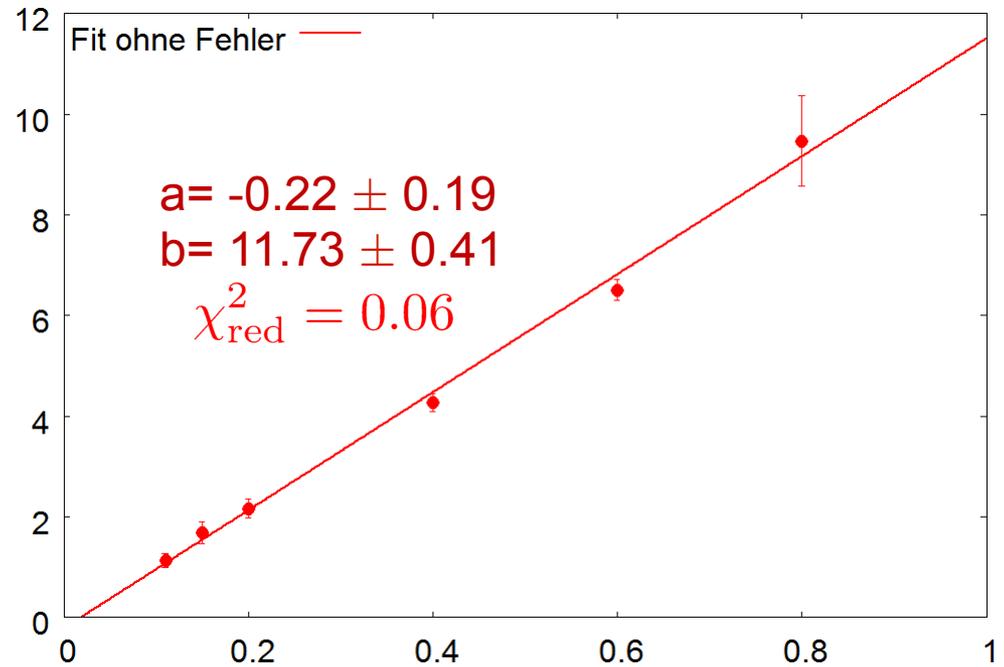
Fit mit  $f(x) = a + b \cdot x$



# Linearer Fit

Ohne Berücksichtigung der  
Unsicherheiten:

Fit mit  $f(x) = a + b \cdot x$



# Linearer Fit

Mit Berücksichtigung der  
Unsicherheiten:

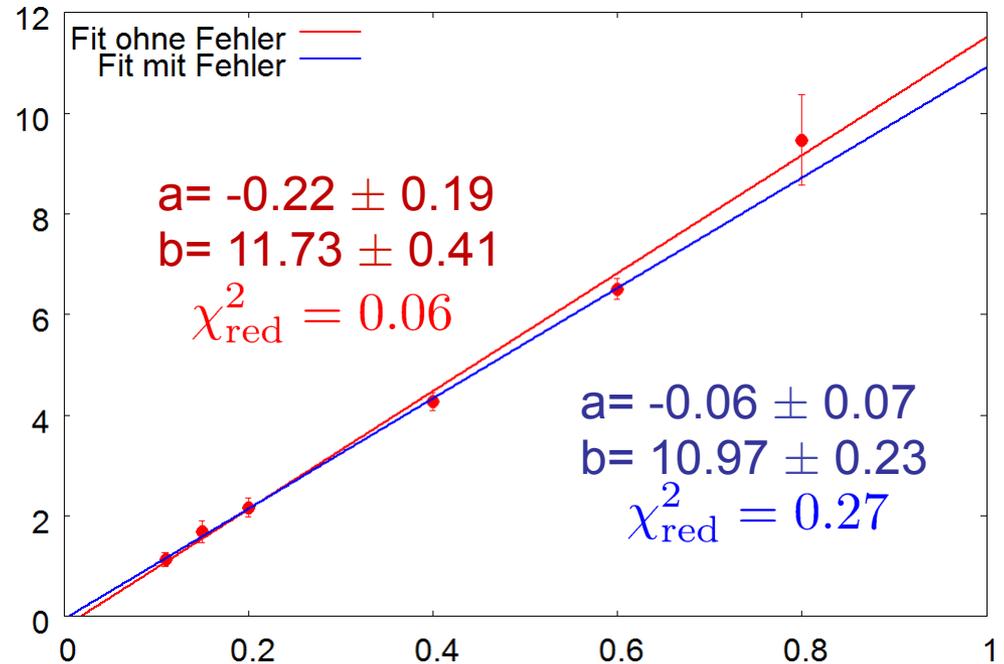
Fit mit  $f(x) = a + b \cdot x$

in gnuplot:

$f(x) = a + b \cdot x$

fit f(x) "datenfile" u 1:2 via a,b (ohne Fehler)

fit f(x) "datenfile" u 1:2:3 via a,b (mit Fehler)



# Linearer Fit

Mit Berücksichtigung der Unsicherheiten:

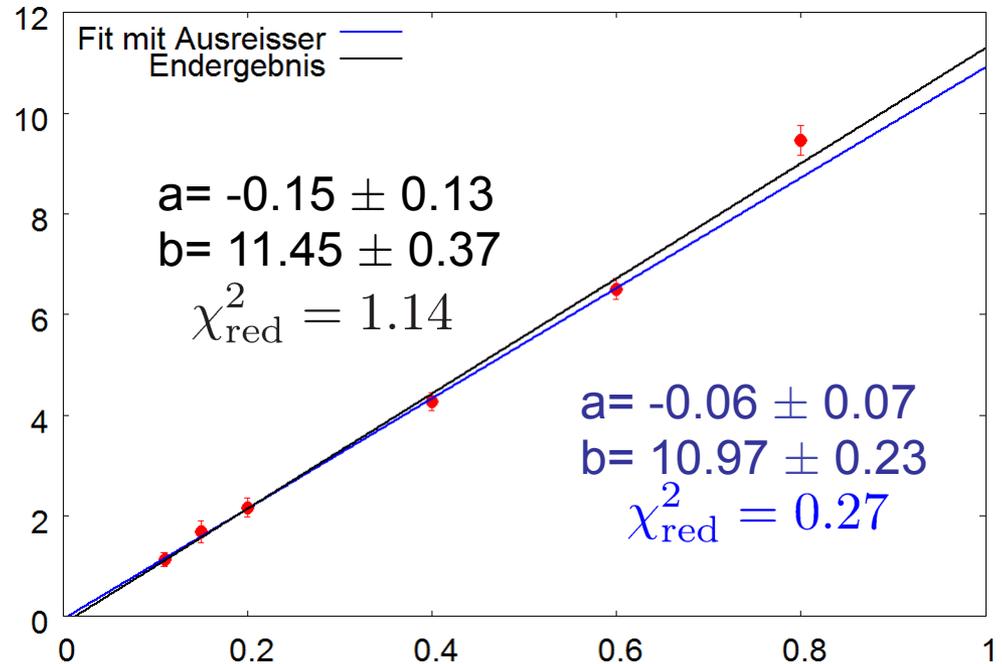
Fit mit  $f(x) = a + b \cdot x$

in gnuplot:

$$f(x) = a + b \cdot x$$

fit f(x) "datenfile" u 1:2 via a,b (ohne Fehler)

fit f(x) "datenfile" u 1:2:3 via a,b (mit Fehler)



# Beispiel Pearson.dat

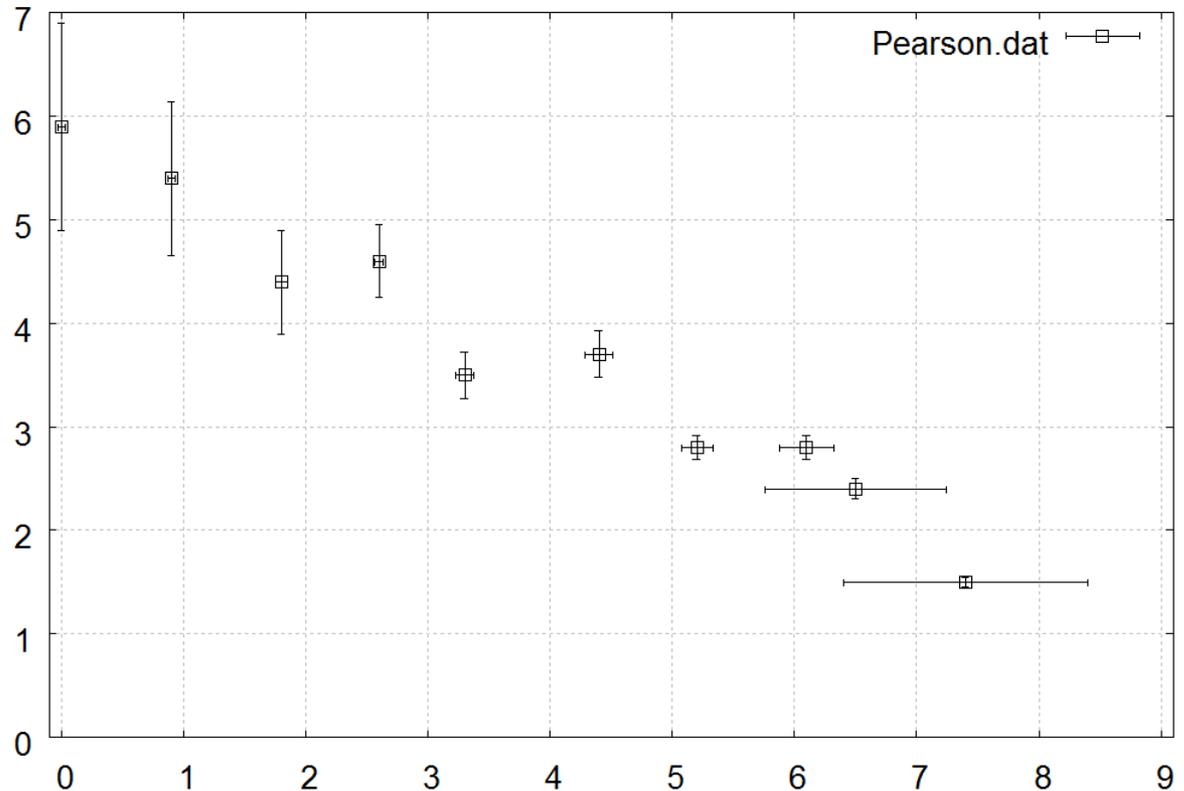
Fit mit  $f(x) = m \cdot x + b$

FitLin(x,y):  
ohne Fehler

FitLinDy(x,y,dy):  
mit y-Fehlern

Gnuplot (mit y-Fehlern):

FitLinDxDy(x,y,dx,dy):  
mit x+y-Fehlern



# Beispiel Pearson.dat

Fit mit  $f(x) = m \cdot x + b$

FitLin(x,y):

ohne Fehler

$m_1 = -0.54$

$b_1 = 5.76$

FitLinDy(x,y,dy):

mit y-Fehlern

$m_2 = -0.61 \pm 0.03$

$b_2 = 6.10 \pm 0.20$

Gnuplot (mit y-Fehlern):

$m = -0.61 \pm 0.06$

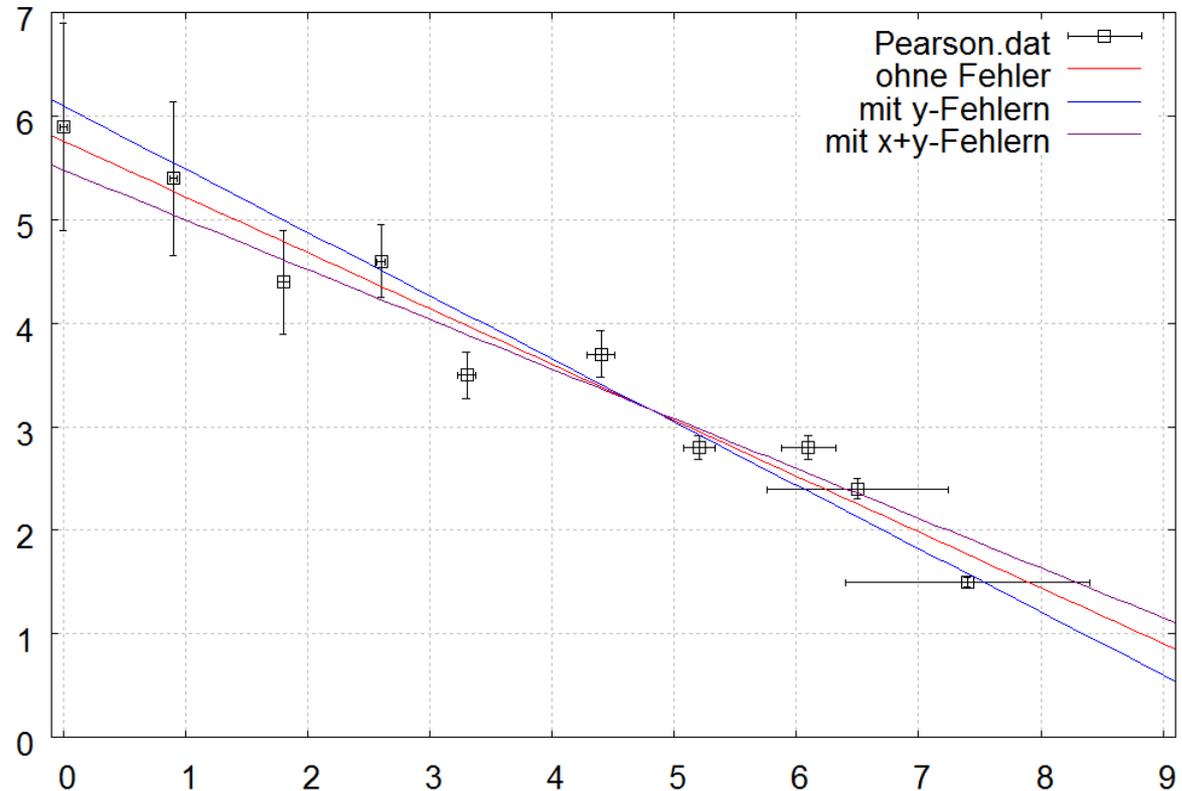
$b = 6.10 \pm 0.42$

FitLinDxDy(x,y,dx,dy):

mit x+y-Fehlern

$m_3 = -0.48 \pm 0.06$

$b_3 = 5.48 \pm 0.29$



Beste Fit unter Berücksichtigung aller Unsicherheiten:

$$f(x) = -0.48(6) \cdot x + 5.48(29)$$

[matlab Routinen von Udo Werner siehe Homepage der Vorlesung]

# Beispiel problem.dat

Fit mit  $f(x) = m \cdot x + b$

FitLinDy(x,y,dy):

mit y-Fehlern

$$m = 2.00 \pm 0.11$$

$$b = 1.00 \pm 0.68$$

Gnuplot:

mit y-Fehlern

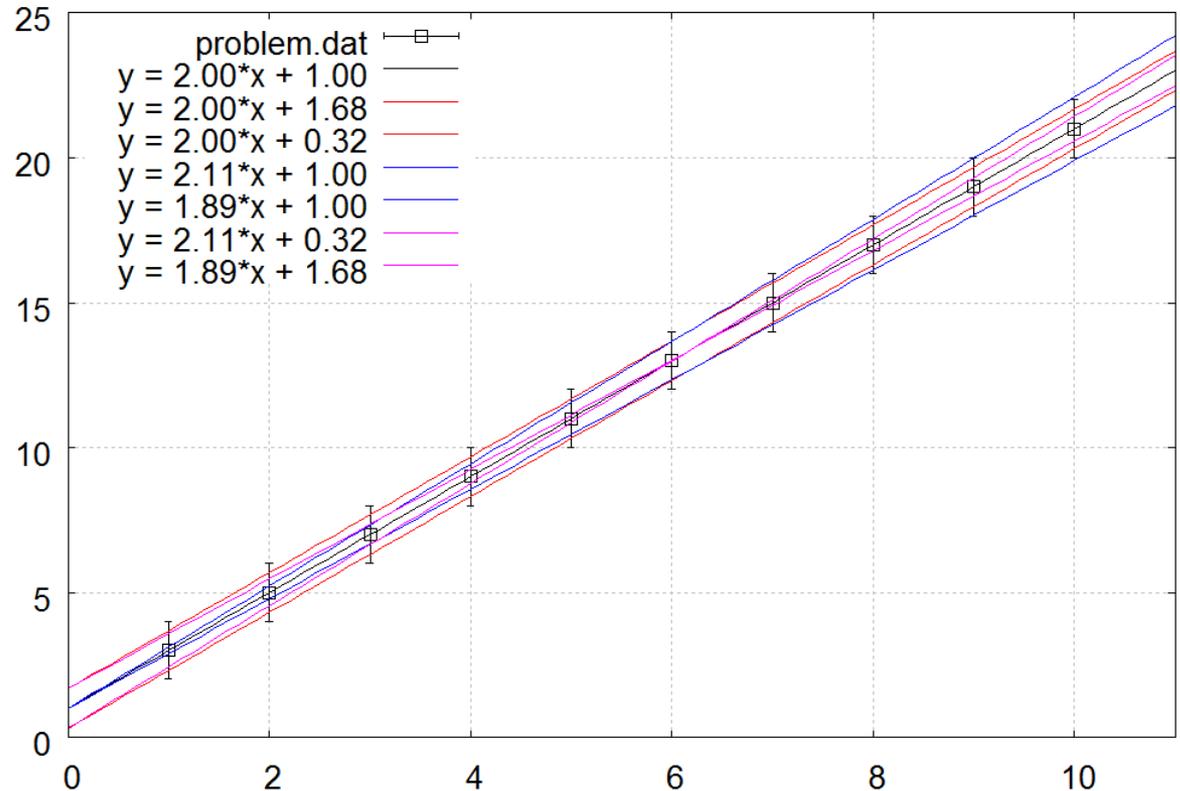
$$m = 2.00 \pm ???$$

$$b = 1.00 \pm ???$$

*Hmmmm....*

*Sum of squared residuals  
is zero. Can't compute errors*

(andere Programme haben das  
gleiche Problem)



Analytisches Ergebnis:

$$m = 2.00 \pm 0.11 \quad b = 1.00 \pm 0.68$$

**Warum?  $\chi^2 = 0!$**  gnuplot benutzt nicht die analytische Berechnung!

# Beispiel problem2.dat

Fit mit  $f(x) = m \cdot x + b$

FitLinDy(x,y,dy):

mit y-Fehlern

$m = 1.995093 \pm 0.058699$

$b = 1.028104 \pm 0.391409$

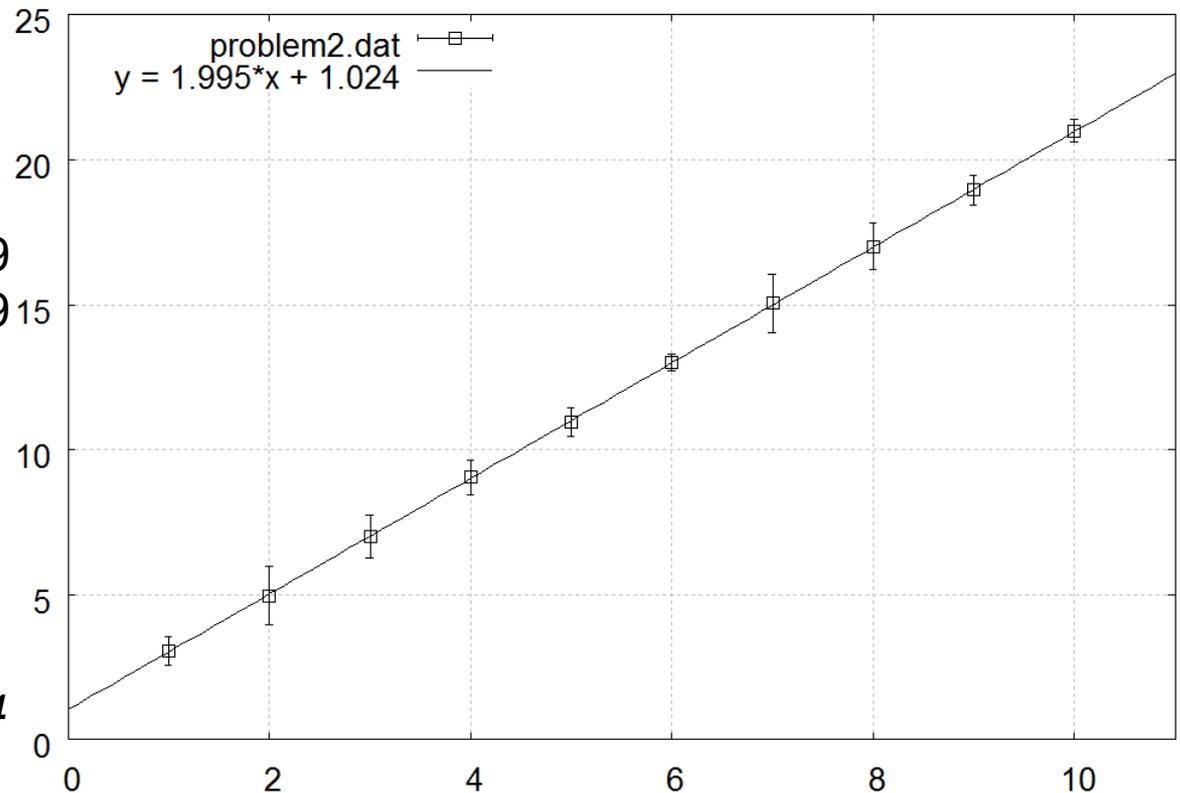
Gnuplot:

mit y-Fehlern

$m = 1.99509 \pm 0.003875$

$b = 1.02810 \pm 0.025840$

*reduced chisquare 0.0044*



# Beispiel problem2.dat

Fit mit  $f(x) = m \cdot x + b$

FitLinDy(x,y,dy):

mit y-Fehlern

$$m = 1.995093 \pm 0.117398$$

$$b = 1.028104 \pm 0.782818$$

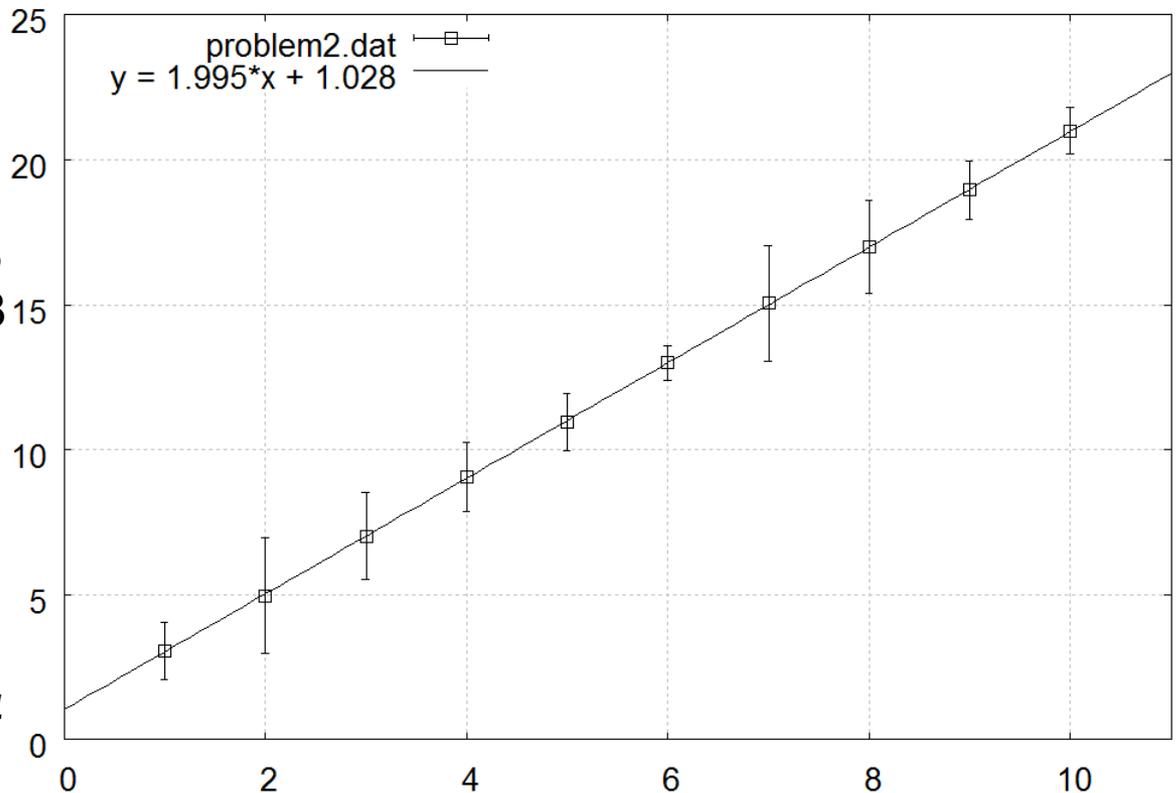
Gnuplot:

mit y-Fehlern

$$m = 1.99509 \pm 0.003875$$

$$b = 1.02810 \pm 0.025840$$

*reduced chisquare 0.0044*



**Verdoppelung der Fehler:**

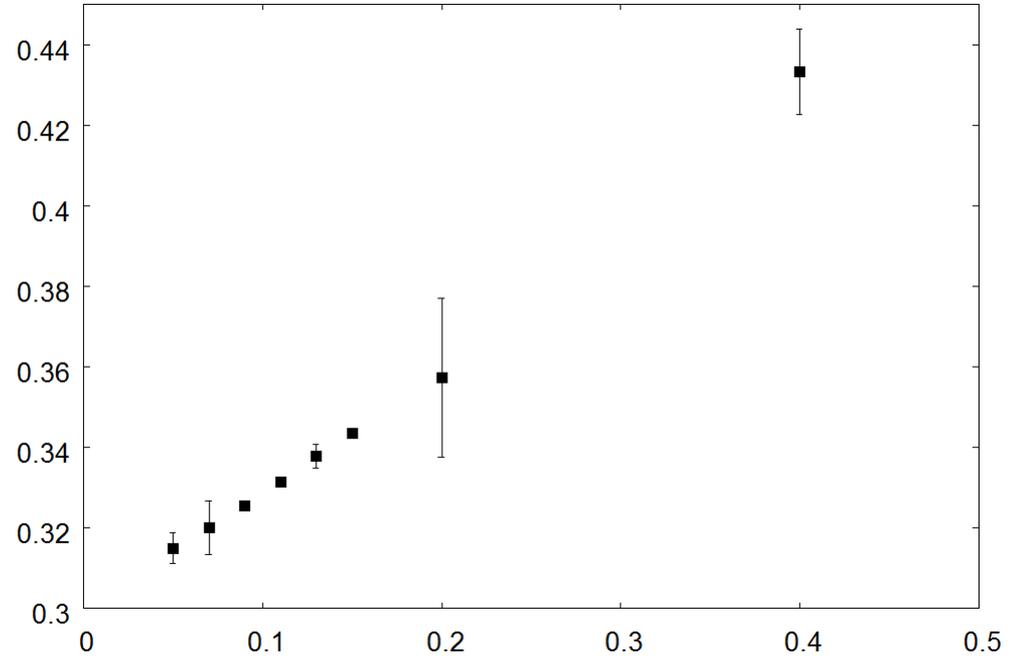
Fehler in der analytischen Rechnung doppelt so gross!

Fehler in gnuplot unverändert und unterschätzt!

**Warum?  $\chi^2$  klein!** gnuplot benutzt nicht die analytische Berechnung!

# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

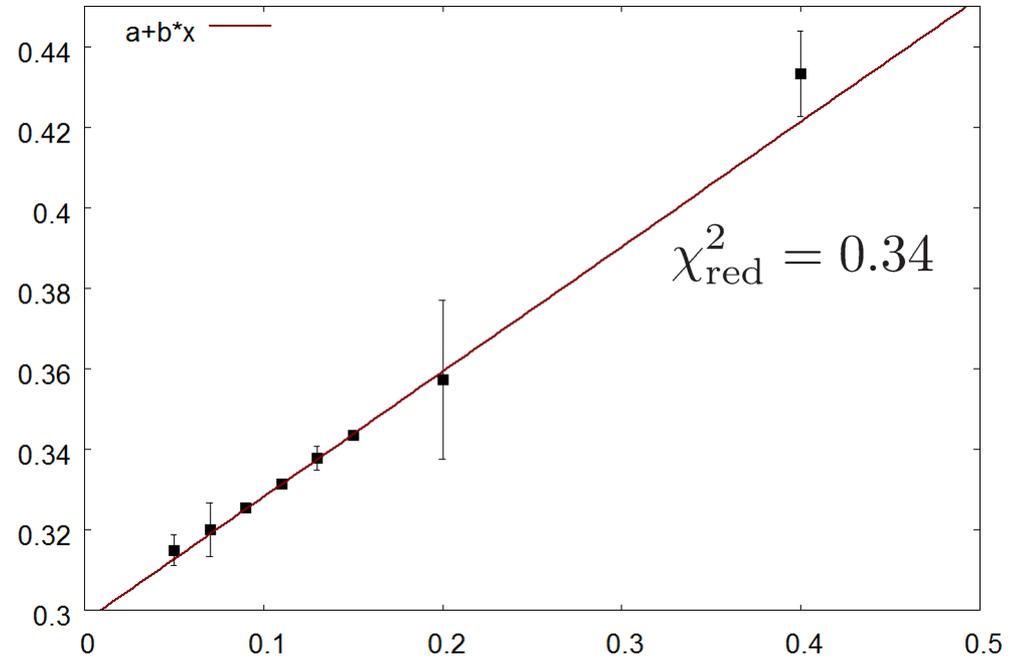


# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten recht gut!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

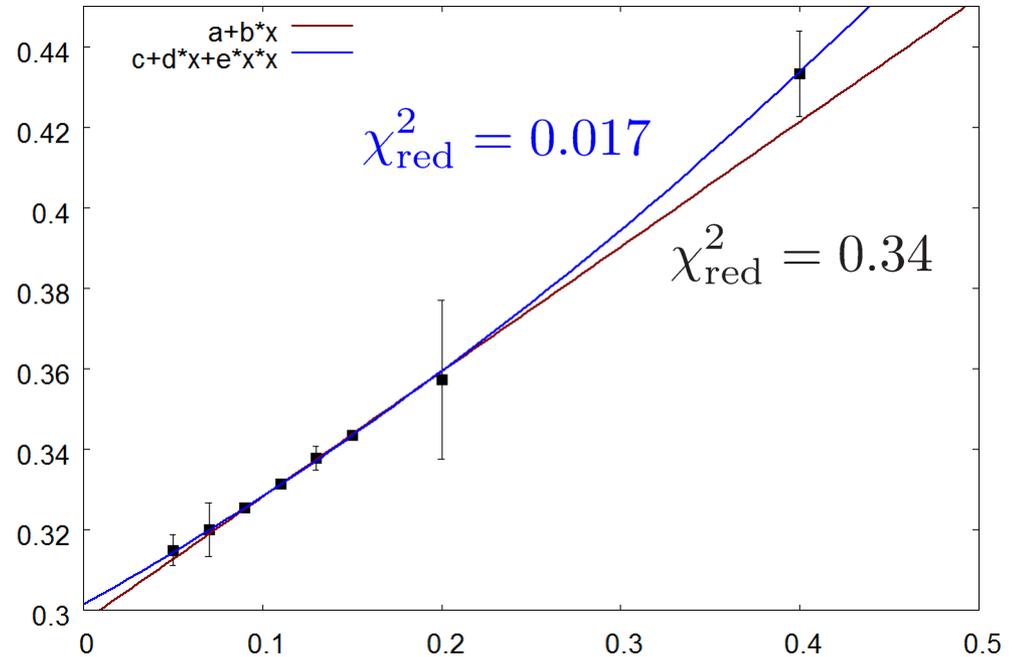
$$f(x) = a + b \cdot x$$

beschreibt die Daten recht gut!

aber auch

$$g(x) = c + d \cdot x + e \cdot x \cdot x$$

beschreibt die Daten recht gut!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

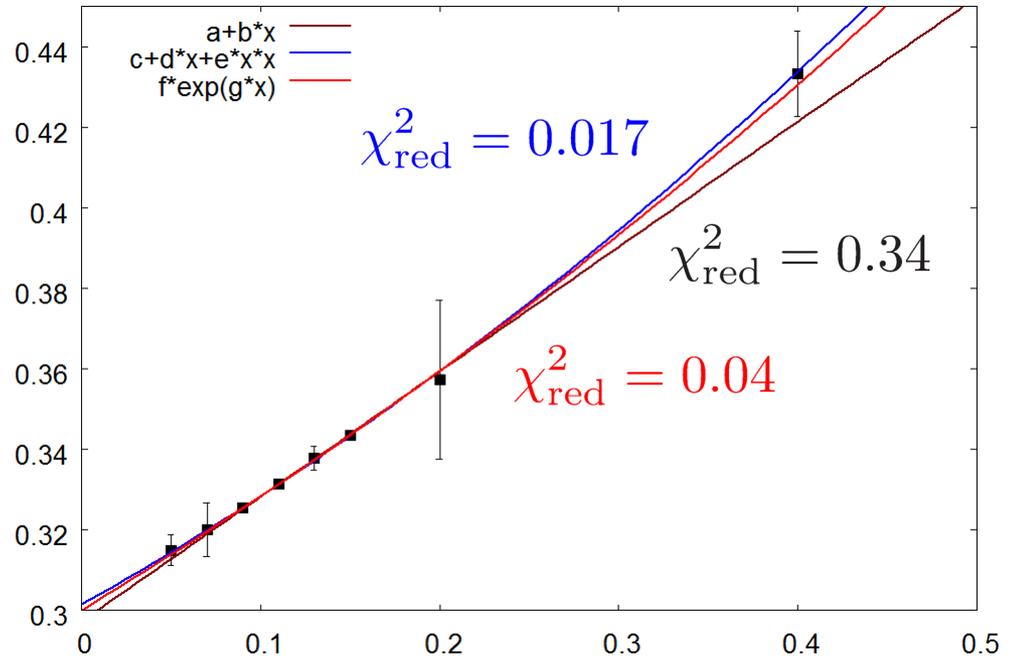
beschreibt die Daten recht gut!

aber auch

$$g(x) = c + d \cdot x + e \cdot x^2$$

beschreibt die Daten recht gut!

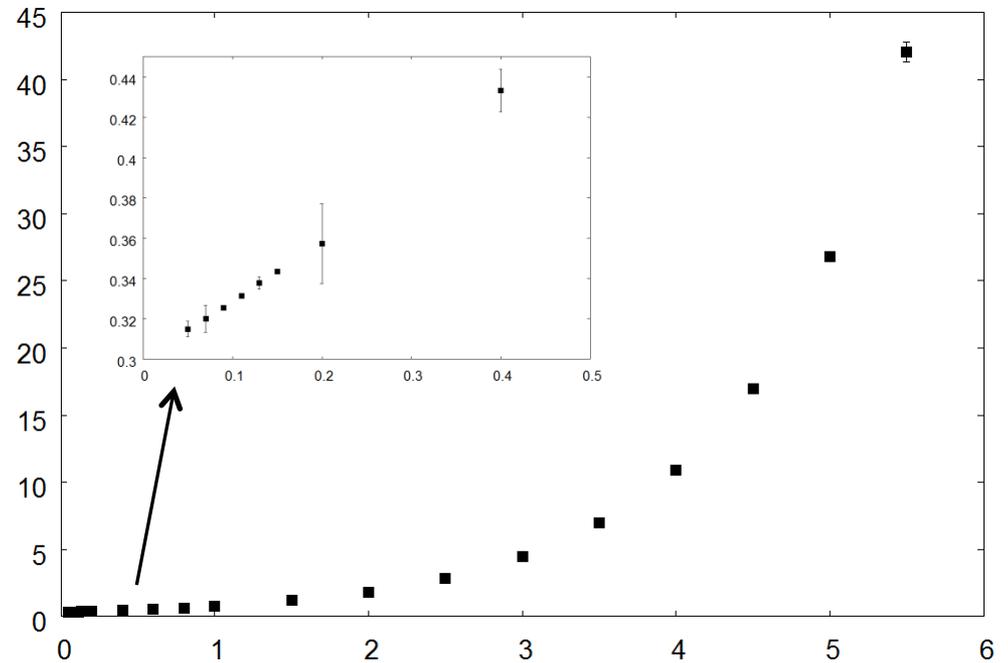
$$h(x) = f \cdot \exp(g \cdot x) \quad \text{ebenso!}$$



Problem: Innerhalb des kleinen Wertebereichs werden die Daten durch alle Ansätze gut beschrieben!

→ Vergrößerung des Wertebereichs

# Weiteres Beispiel



Problem: Innerhalb des kleinen Wertebereichs werden die Daten durch alle Ansätze gut beschrieben!

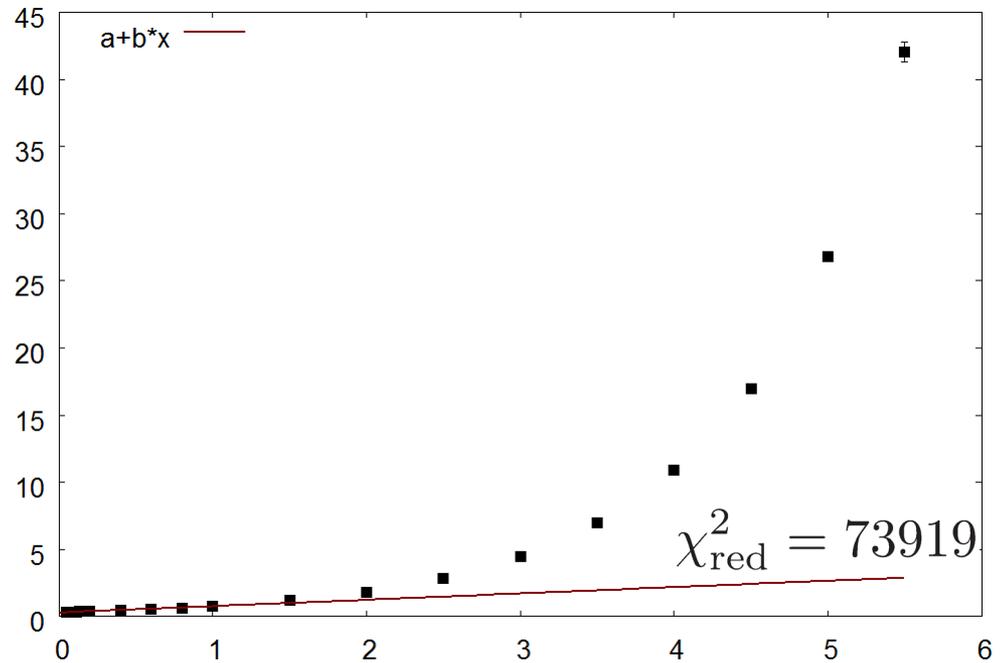
→ Vergrößerung des Wertebereichs

# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

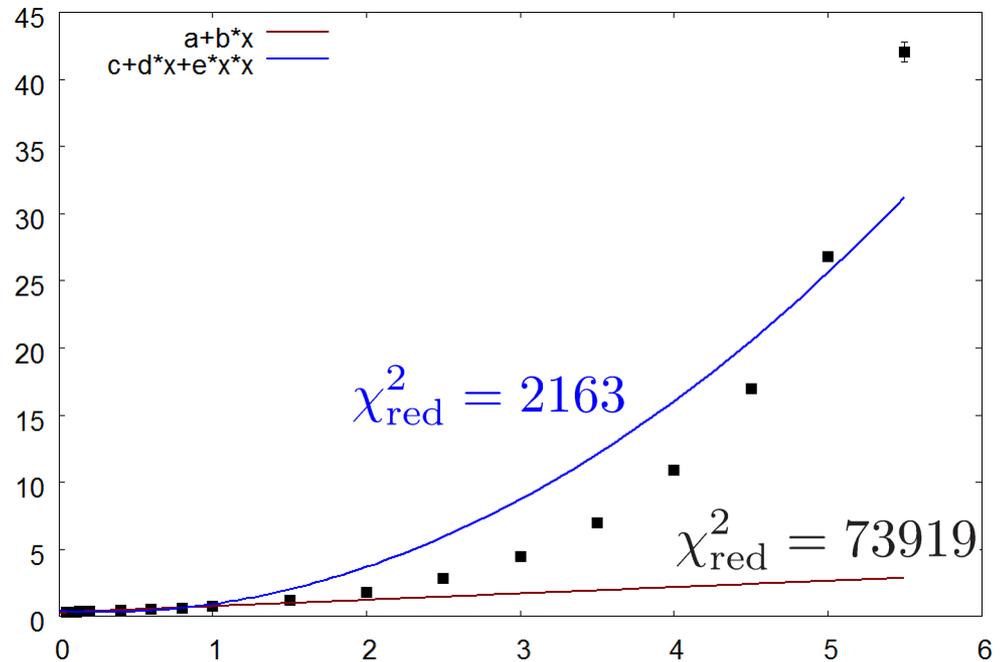
$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!

aber auch

$$g(x) = c + d \cdot x + e \cdot x \cdot x$$

beschreibt die Daten nur für kleine x!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!

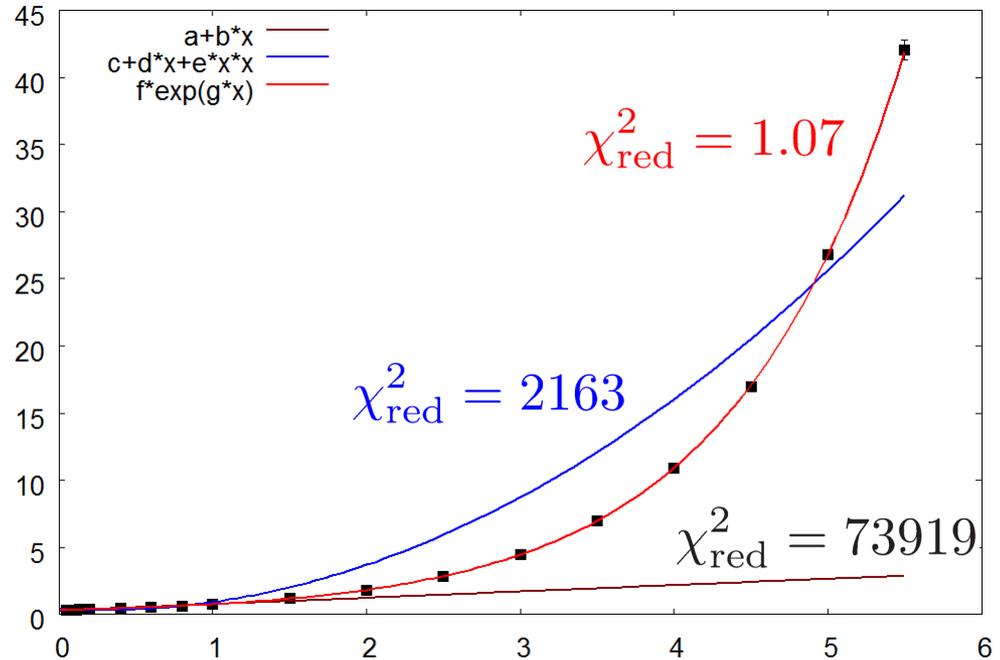
aber auch

$$g(x) = c + d \cdot x + e \cdot x \cdot x$$

beschreibt die Daten nur für kleine x!

$$h(x) = f \cdot \exp(g \cdot x)$$

beschreibt die Daten im gesamten Wertebereich!



# nicht-lineare Abhängigkeit

Bsp.:

Messung der

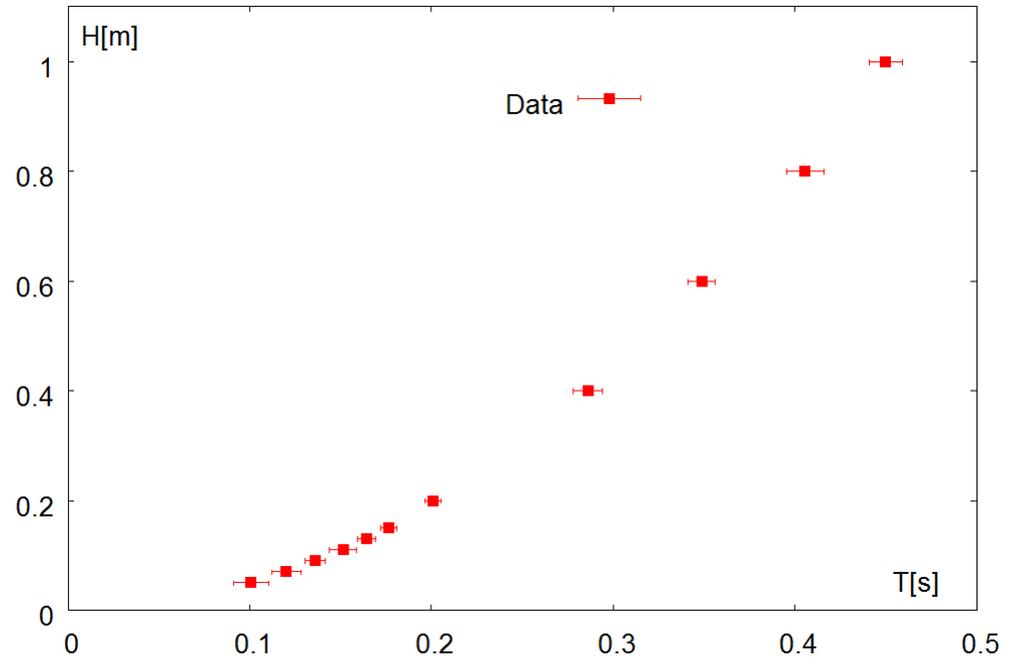
Gravitationsbeschleunigung  $g$

durch Bestimmung der Fallzeit  $T$

einer Kugel in Abhängigkeit von der

Fallhöhe  $H$ :

$$H(T) = \frac{1}{2}gT^2$$



# nicht-lineare Abhängigkeit

Bsp.:

Messung der

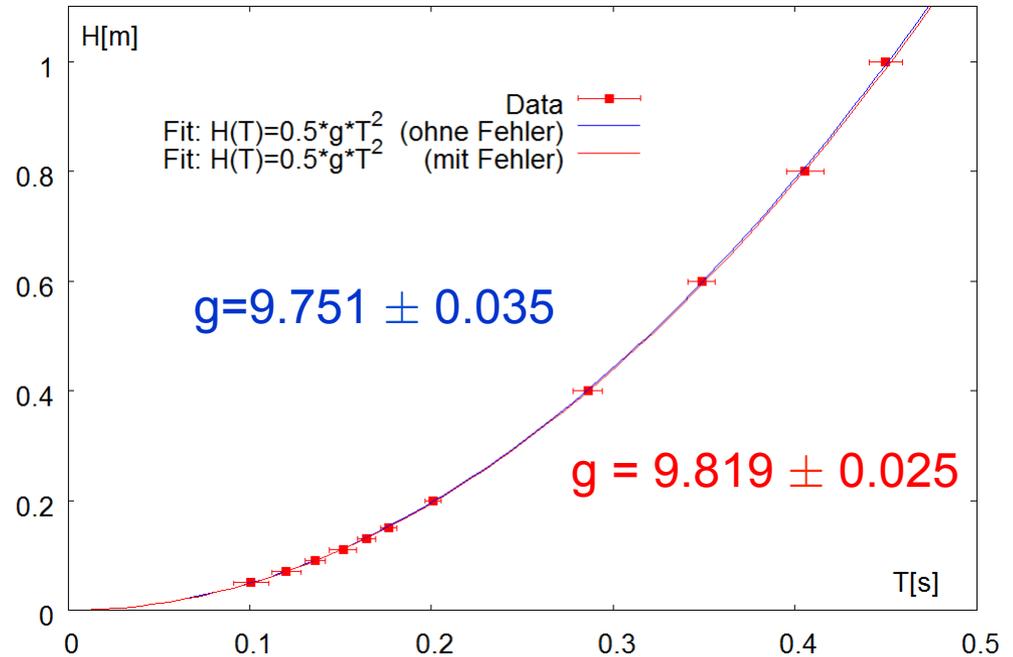
Gravitationsbeschleunigung  $g$

durch Bestimmung der Fallzeit  $T$

einer Kugel in Abhängigkeit von der

Fallhöhe  $H$ :

$$H(T) = \frac{1}{2}gT^2$$



# Linearisierung der Daten

Bsp.:

Messung der

Gravitationsbeschleunigung  $g$

durch Bestimmung der Fallzeit  $T$

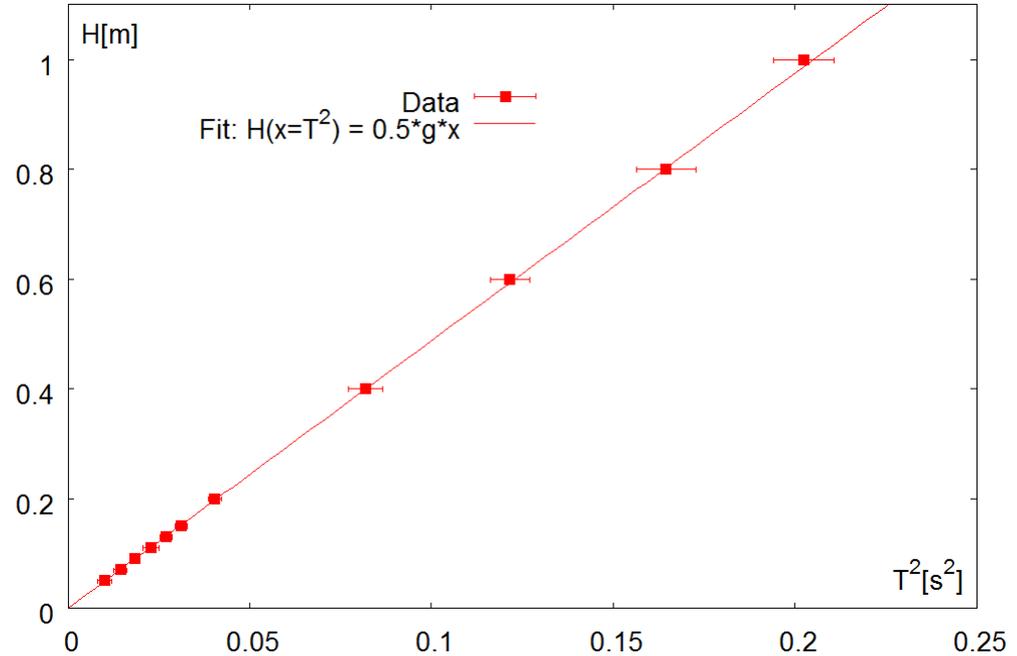
einer Kugel in Abhängigkeit von der

Fallhöhe  $H$ :

$$H(T) = \frac{1}{2}gT^2$$

Benutze  $x=T^2$  auf der x-Achse:

$$H(T) = \frac{1}{2}gx$$



# Systematische Fehler

Hier scheint die lineare Abhängigkeit

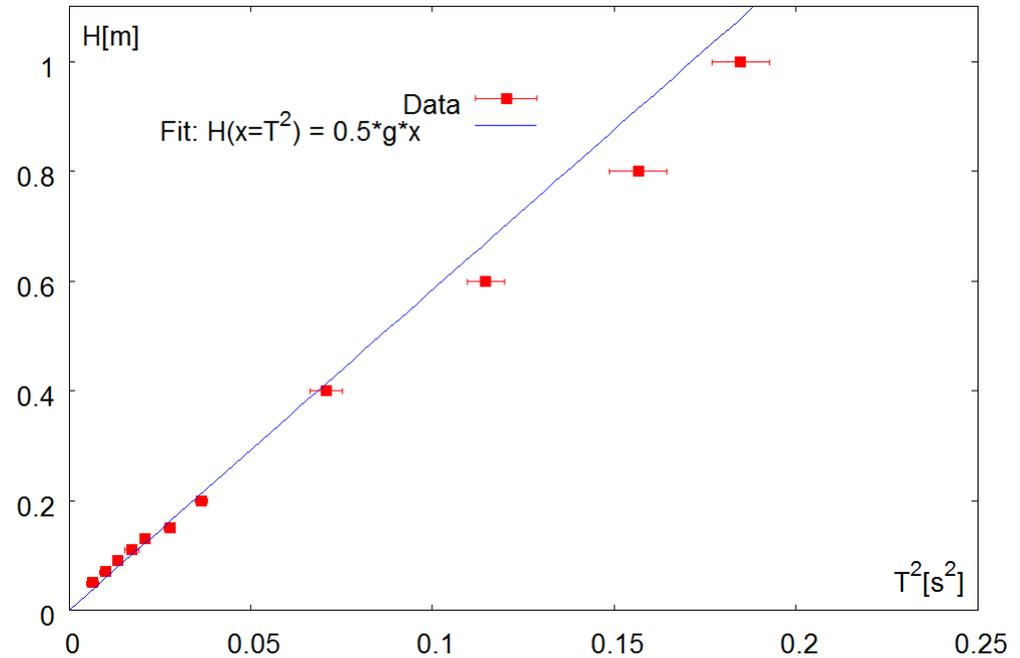
nicht zu passen!?

→ evtl. auf Grund von systematischen Fehlern oder Messfehlern

Daher sollte man im Ansatz eine

Konstante benutzen:

$$H(T) = \frac{1}{2}gT^2 + const$$



# Systematische Fehler

Hier scheint die lineare Abhängigkeit

nicht zu passen!?

→ evtl. auf Grund von systematischen Fehlern oder Messfehlern

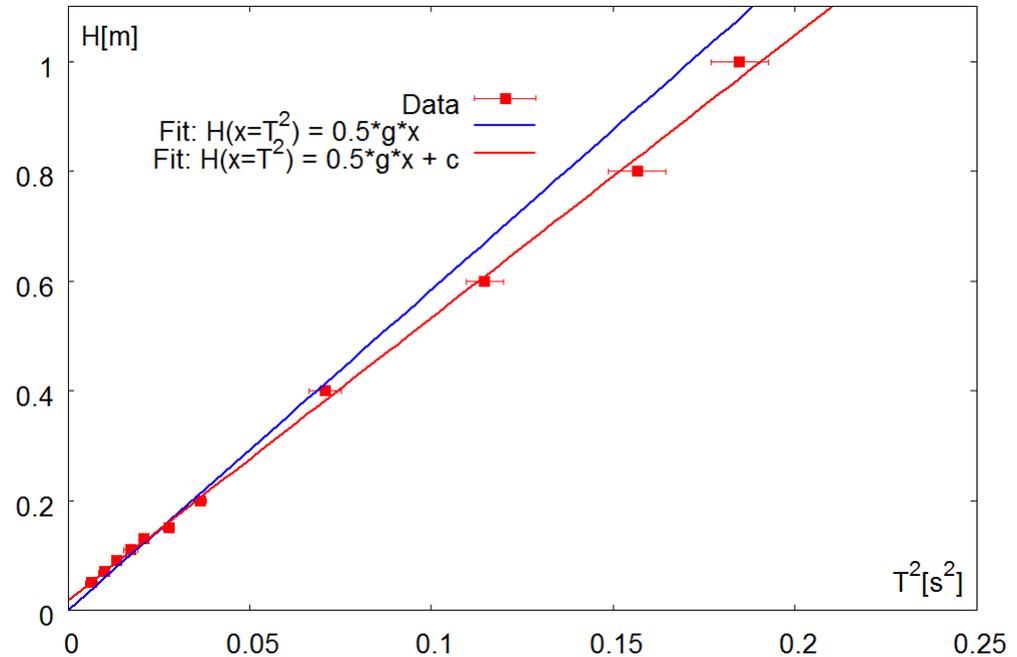
Daher sollte man im Ansatz eine

Konstante benutzen:

$$H(T) = \frac{1}{2}gT^2 + const$$

Ist die Konstante innerhalb der Fehler mit Null verträglich, so entsprechen die Daten der theoretischen Vorhersage.

Ansonsten sollte man untersuchen und diskutieren woher die Abweichung kommt!



# Transformationen

Bsp.:

Messung der

Gravitationsbeschleunigung  $g$

durch Bestimmung der Fallzeit  $T$

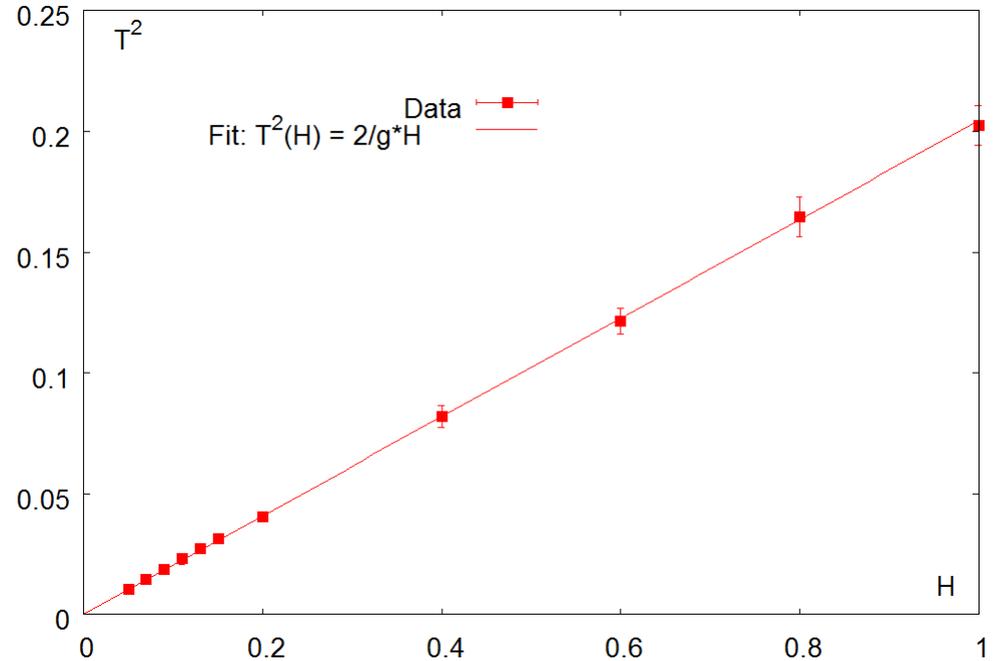
einer Kugel in Abhängigkeit von der

Fallhöhe  $H$ :

$$H(T) = \frac{1}{2}gT^2$$

Umstellen der Gleichung  $H \leftrightarrow T^2$ :

$$T^2(H) = 2/g * H$$



# Transformationen

Bsp.:

Messung der

Gravitationsbeschleunigung  $g$

durch Bestimmung der Fallzeit  $T$

einer Kugel in Abhängigkeit von der

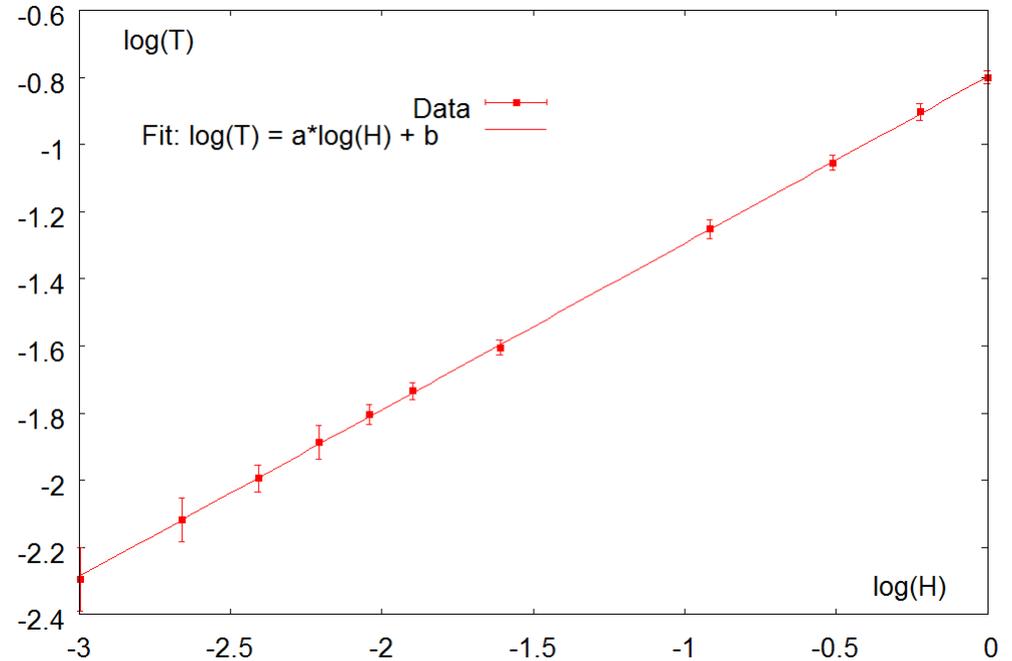
Fallhöhe  $H$ :

$$H(T) = \frac{1}{2}gT^2$$

Umstellen der Gleichung  $H \leftrightarrow T^2$ :

$$T^2(H) = 2/g * H$$

$$\log(T) = 1/2 * \log(H) + 1/2 * \log(2/g)$$



# Einschub: Fehlerfortpflanzung

Messpunkte  $(x_1, y_1 \pm \sigma_1), \dots (x_N, y_N \pm \sigma_N)$

Die Daten sollen mit einer Funktion  $f(y_i)$  transformiert werden!

**Wie ändern sich die Fehler dabei?**

Allgemein:  $f(x_1, x_2, \dots)$

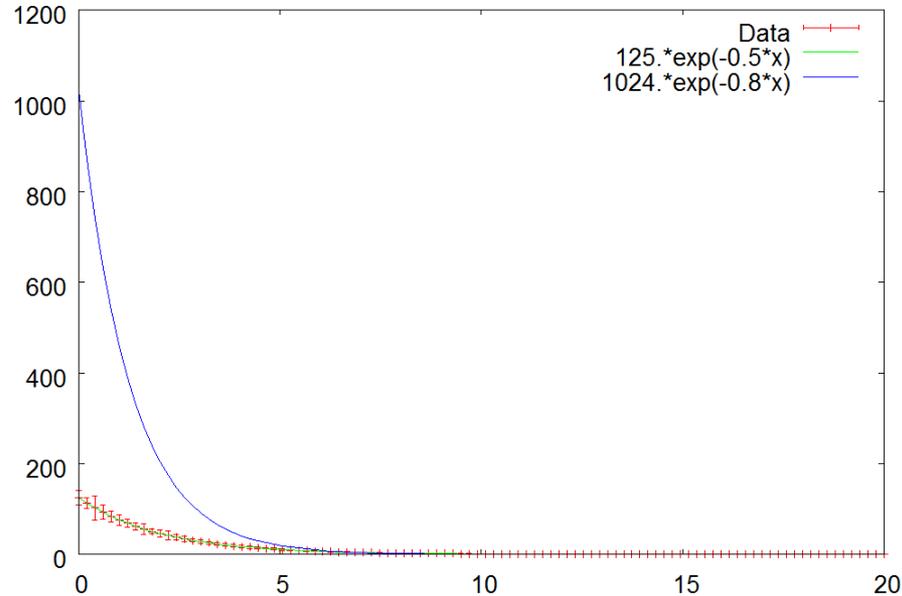
Maximalfehler: 
$$\Delta f = \left| \frac{\partial f}{\partial x_1} \right| \Delta x_1 + \left| \frac{\partial f}{\partial x_2} \right| \Delta x_2 + \dots$$

Gaußsche Fehlerfortpflanzung:

$$\Delta f = \sqrt{\left( \frac{\partial f}{\partial x_1} \Delta x_1 \right)^2 + \left( \frac{\partial f}{\partial x_2} \Delta x_2 \right)^2 + \dots}$$

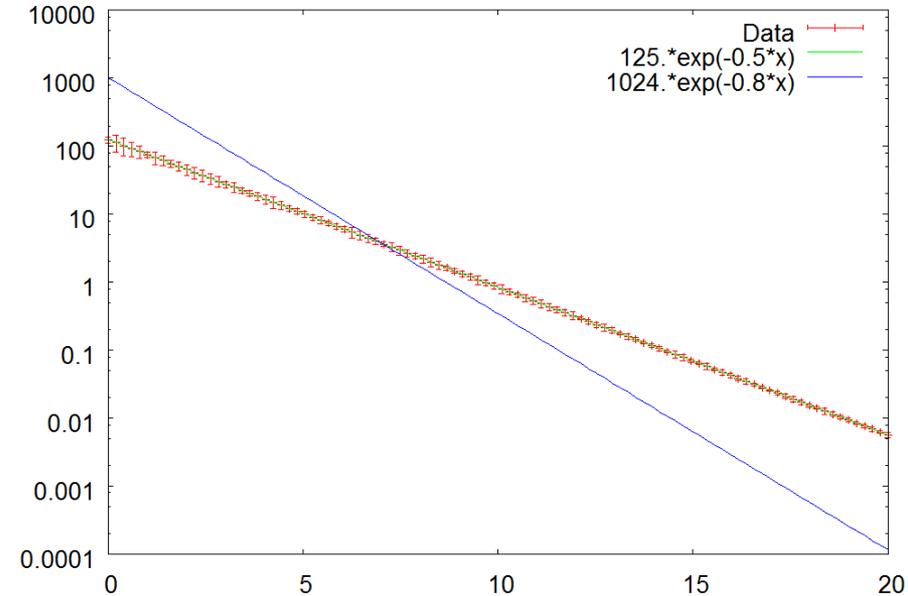
(genauere Besprechung in einer der nächsten Vorlesungen)

# Logarithmische Skalen



Durch den starken exponentiellen Abfall sind die Daten bei großen x-Werten kaum sichtbar.

Ob es wirklich ein exponentieller Zusammenhang ist, ist schwer zu erkennen



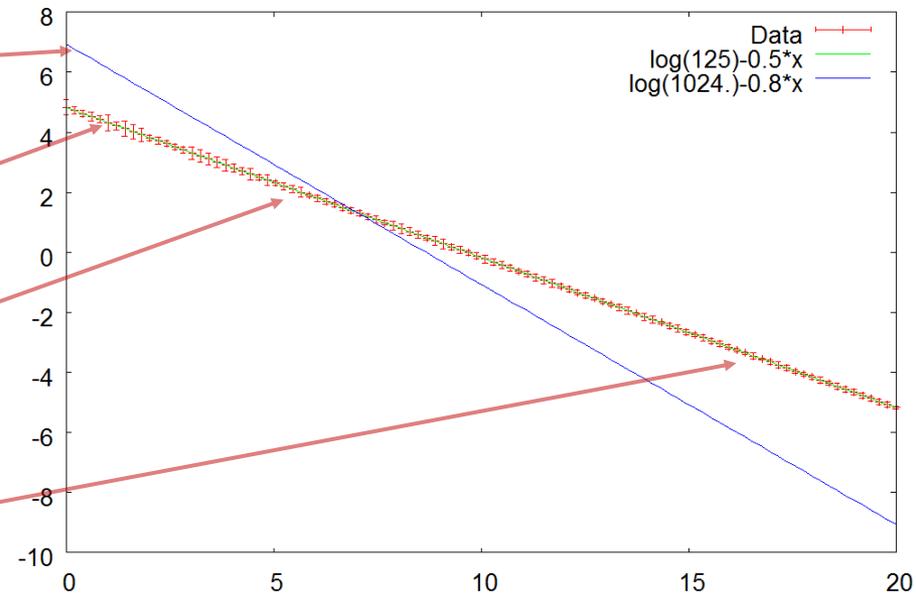
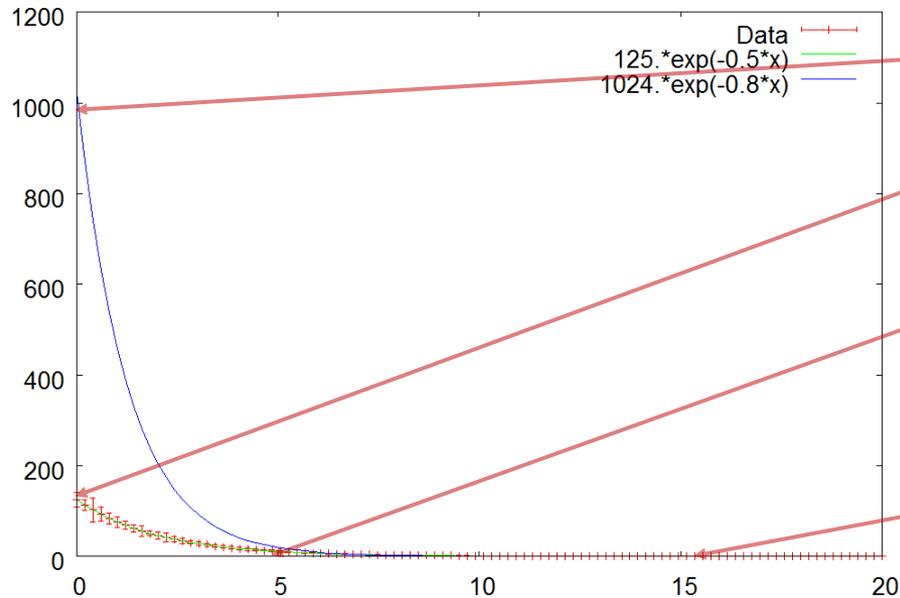
Zur guten Darstellung aller Werte über verschiedene Größenordnungen hinweg ist eine logarithmischen Skala sinnvoller!

Der exponentielle Verlauf wird zu einem linearen Verlauf.

exp. Verlauf  $\exp(m \cdot x) \rightarrow$  Steigung  $m \cdot x$

# Logarithmische Skalen

zunächst halb-logarithmisch: x-Achse linear und y-Achse logarithmisch



Daten  $(x_i, y_i \pm \Delta y_i), \dots$

Log-Daten  $(x_i, \log(y_i) \pm \Delta y_i / y_i), \dots$

Fehlerfortpflanzung für  $\log(y)$ :

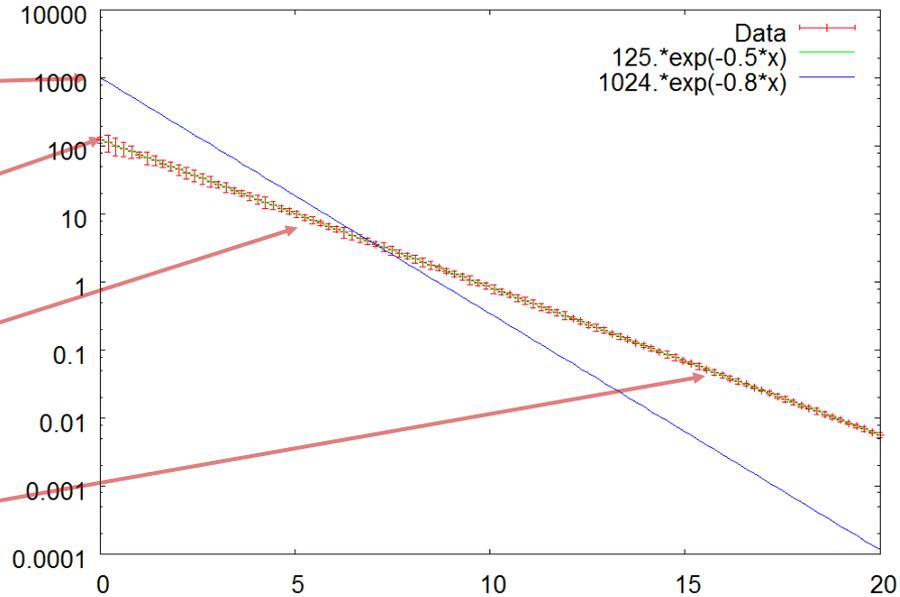
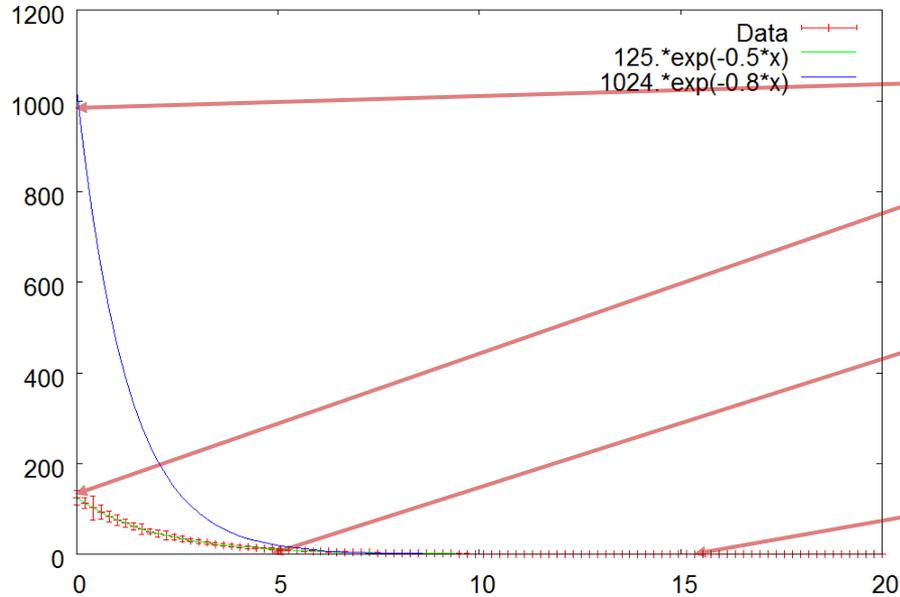
$$\begin{aligned} \Delta \log(y) &= \left| \frac{\partial \log(y)}{\partial y} \right| \Delta y \\ &= \frac{\Delta y}{|y|} \end{aligned}$$

Vorteil: hier wieder Linearisierung

$f(x) = a \cdot \exp(b \cdot x)$  wird zu

$$\log f(x) = \log(a) + b \cdot x$$

# Logarithmische Skalen



Daten  $(x_i, y_i \pm \Delta y_i), \dots$

set logscale y

plot "datenfile" using 1:2:3 with errors

oder: Änderung der Skala

gnuplot: set log y

**Zum Plotten ist dies besser!**

**Zum Fitten besser Linearisierung ausnutzen!**

# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!

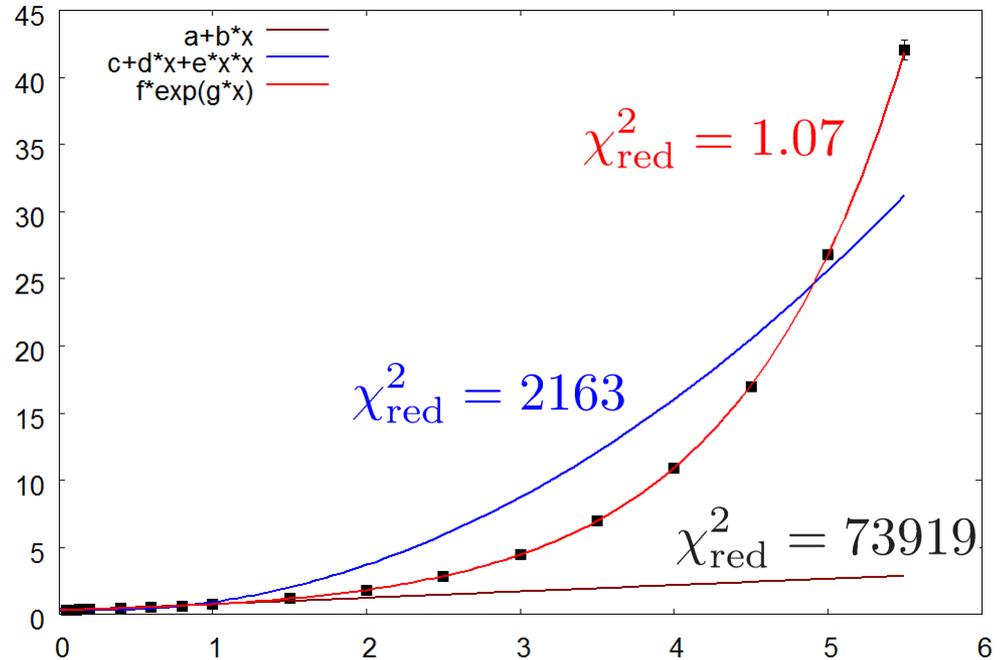
aber auch

$$g(x) = c + d \cdot x + e \cdot x \cdot x$$

beschreibt die Daten nur für kleine x!

$$h(x) = f \cdot \exp(g \cdot x)$$

beschreibt die Daten im gesamten Wertebereich!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!

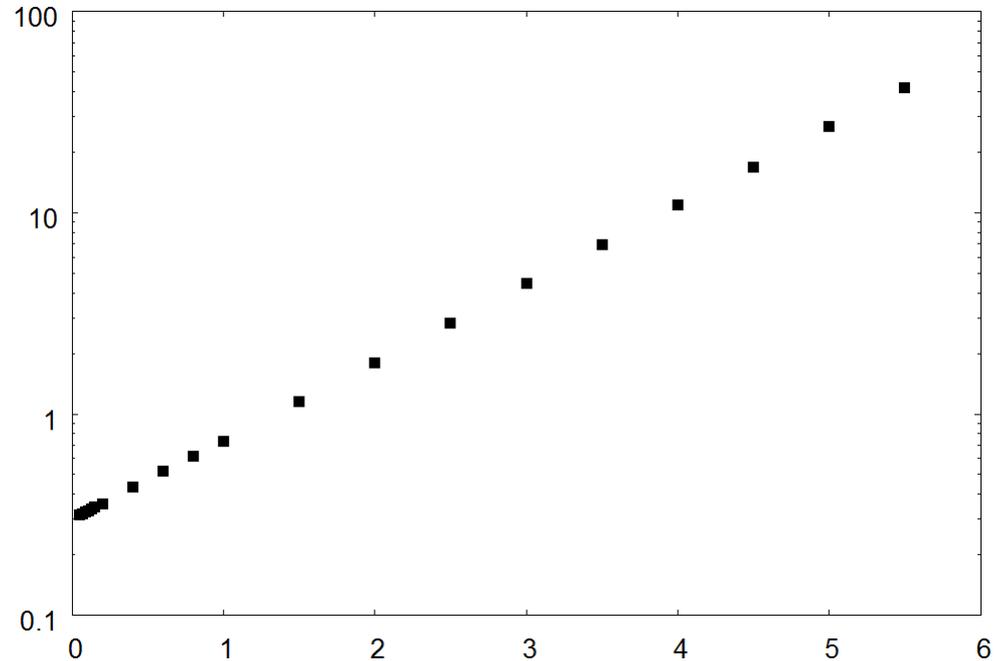
aber auch

$$g(x) = c + d \cdot x + e \cdot x^2$$

beschreibt die Daten nur für kleine x!

$$h(x) = f \cdot \exp(g \cdot x)$$

beschreibt die Daten im gesamten Wertebereich!



# Weiteres Beispiel

Zeigen diese Daten auch einen linearen Zusammenhang?

$$f(x) = a + b \cdot x$$

beschreibt die Daten nur für kleine x!

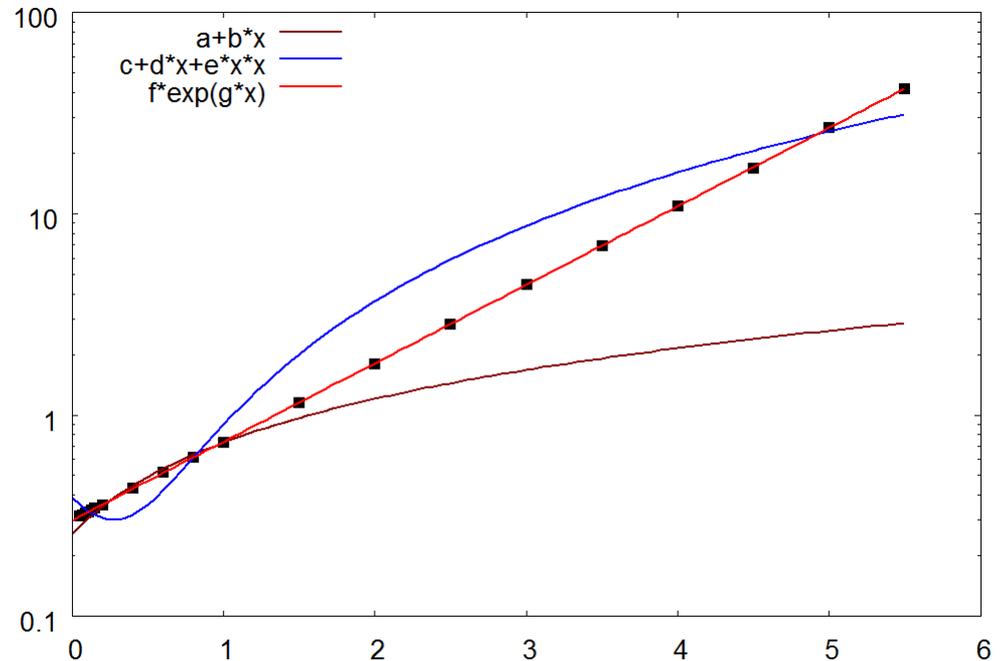
aber auch

$$g(x) = c + d \cdot x + e \cdot x^2$$

beschreibt die Daten nur für kleine x!

$$h(x) = f \cdot \exp(g \cdot x) \quad \rightarrow \quad \text{linear auf logarithmischer Skala}$$

beschreibt die Daten im gesamten Wertebereich!

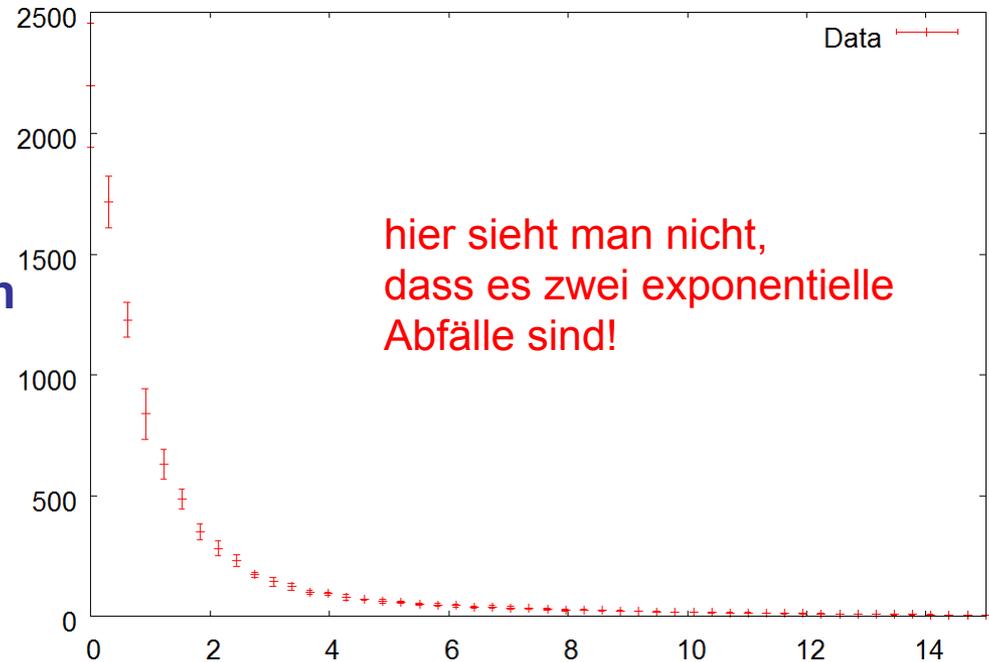


# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Beispielsweise beim radioaktiven Zerfall zweier Isotope.

$N(t)$  ist die Zählrate von Elektronen in einem Zählrohr.

$\lambda_1$  und  $\lambda_2$  die Zerfallskonstanten der beiden Isotope,  $\lambda_i = (\ln 2)/T_i$ , wobei  $T_i$  die Halbwertszeiten sind.

# Logarithmische Skalen

ein komplizierteres Beispiel:

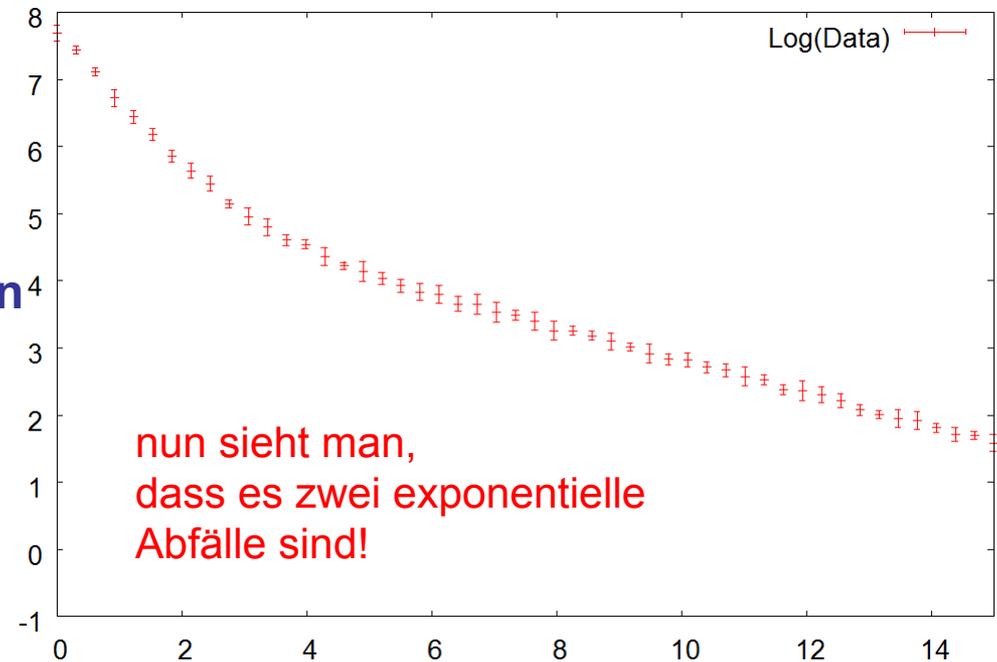
## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$

Annahme:  $\lambda_2 < \lambda_1$

für große t:  $\exp(-\lambda_2 t) \gg \exp(-\lambda_1 t)$  und die zweite Exponentialfunktion dominiert

für kleine t:  $\exp(-\lambda_1 t) \gg \exp(-\lambda_2 t)$  und die erste Exponentialfunktion dominiert

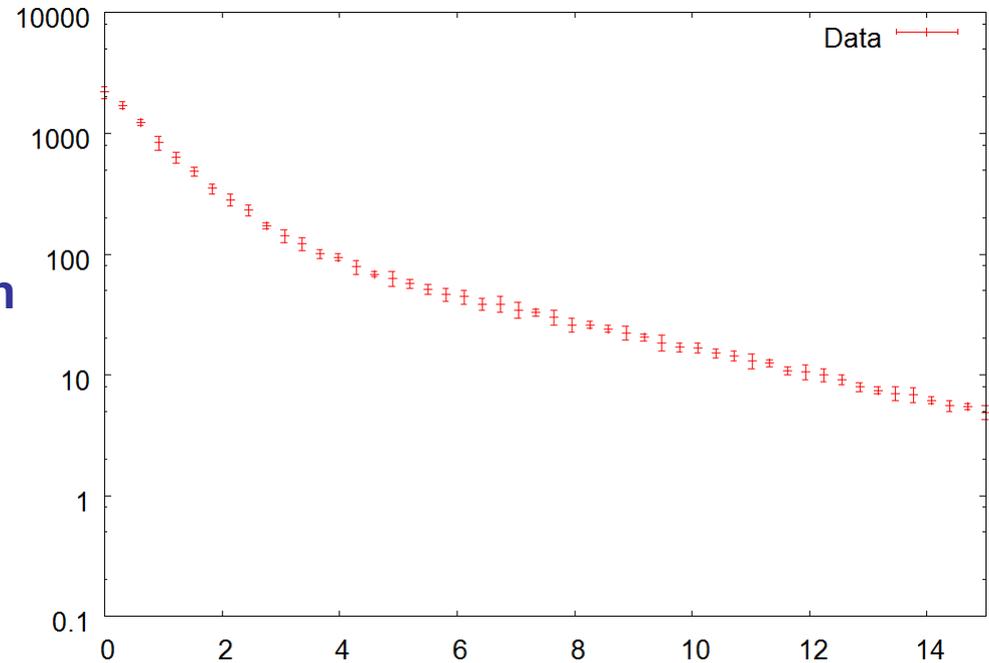


# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Fit mit 4 Parametern?

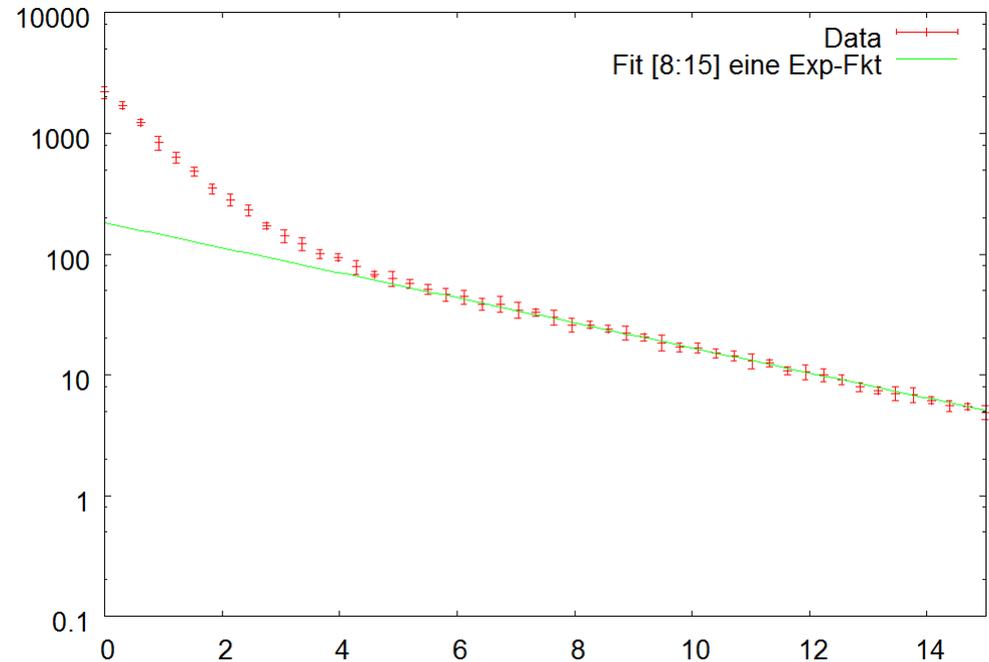
- instabil und abhängig von Startwerten der Parameter
- Abschätzung der Startwerte schwierig

# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Fit zunächst mit einer Exponentialfunktion bei großen t:

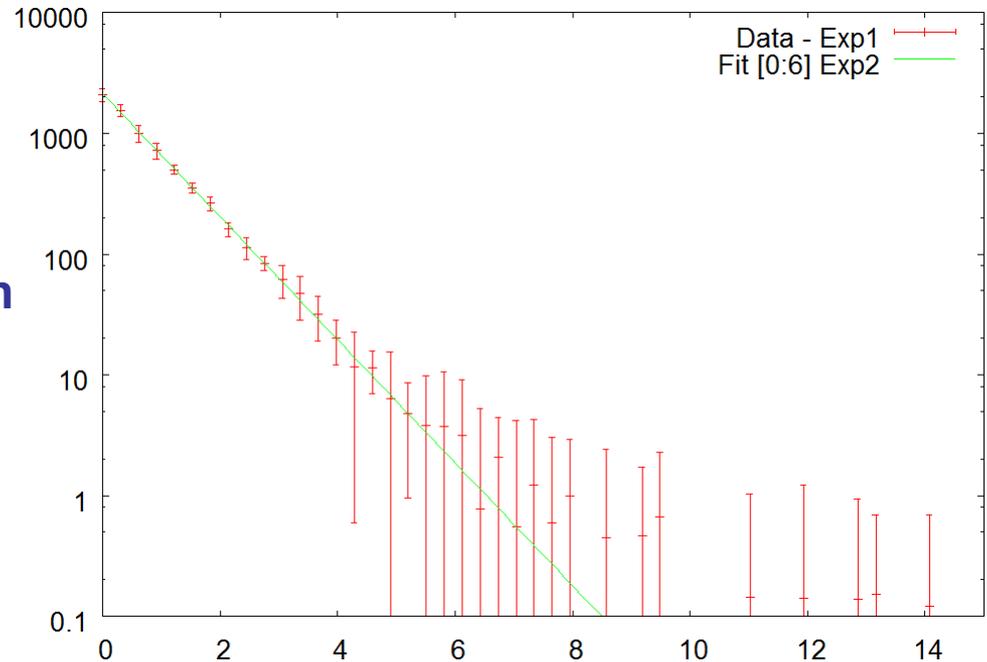
gnuplot:  $n_2(t) = \log(N_2) - I_2 \cdot t$   
fit [8:15] n2(x) "Data" u 1:(log(\$2)):((\$3/\$2)) via N2,I2

# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Subtrahiere das Ergebnis für  $n_2(t)$  von den Daten:

gnuplot:  $n_2(t) = \log(N_2) - I_2 \cdot t$

fit [8:15]  $n_2(x)$  "Data" u 1:( $\log(\$2)$ ):( $\$3/\$2$ ) via  $N_2, I_2$

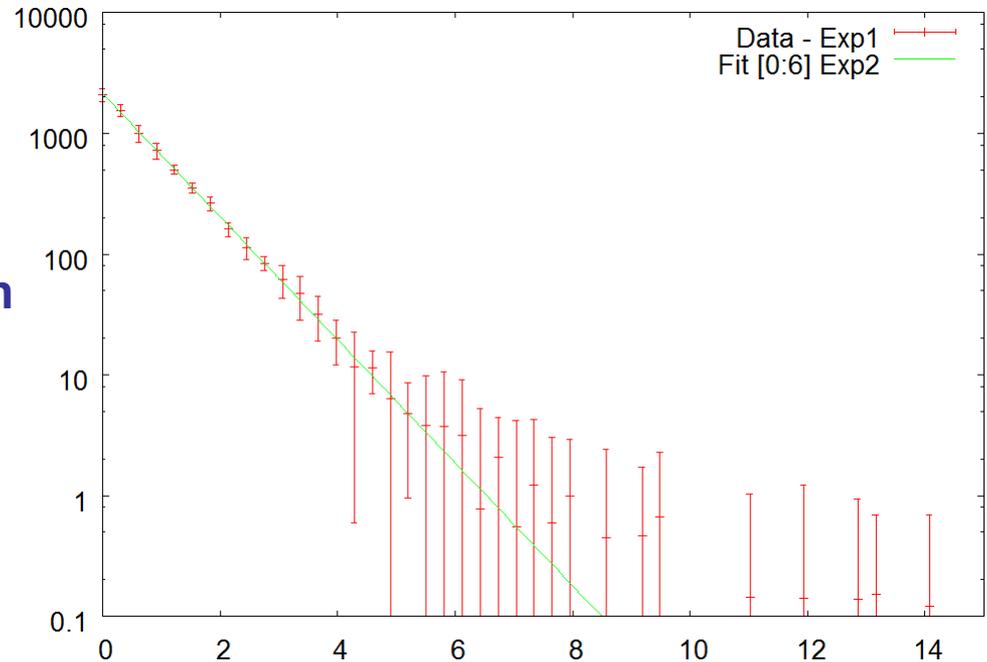
plot "Data" u 1:( $\$2 - n_2(x)$ ):( $\$3$ ) w e

# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Fit mit einer Exponentialfunktion bei kleinen t:

gnuplot:  $n2(t) = \log(N2) - I2 * t$

fit [8:15] n2(x) "Data" u 1:(log(\$2)):((\$3/\$2)) via N2,I2

plot "Data" u 1:(\$2-n2(x)):((\$3)) w e

$n1(t) = \log(N1) - I1 * t$

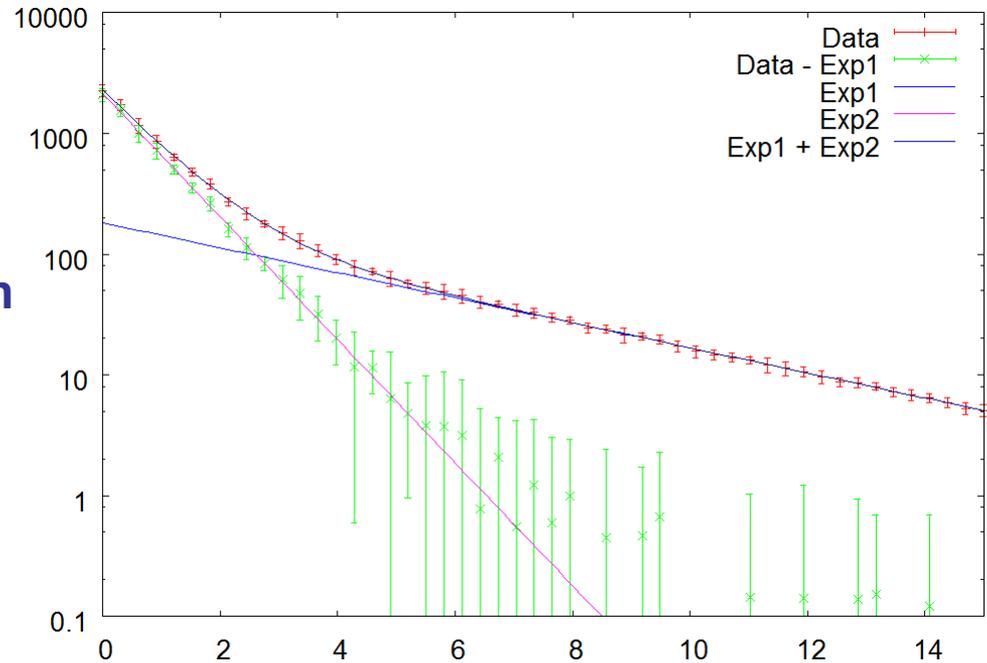
fit [0:6] n1(x) "Data" u 1:(log(\$2-n2(x))):(\$3/\$2) via N1,I1

# Logarithmische Skalen

ein komplizierteres Beispiel:

## Summe zweier Exponentialfunktionen

$$N(t) = N_1 e^{-\lambda_1 t} + N_2 e^{-\lambda_2 t}$$



Vorteile: Es sind nur lineare Fits nötig  
jeweils nur zwei Parameter für die Fits  
und Fehlerberechnung ist einfacher  
Fits mit vielen Parametern meist instabil  
und Fehlerabschätzung schwieriger

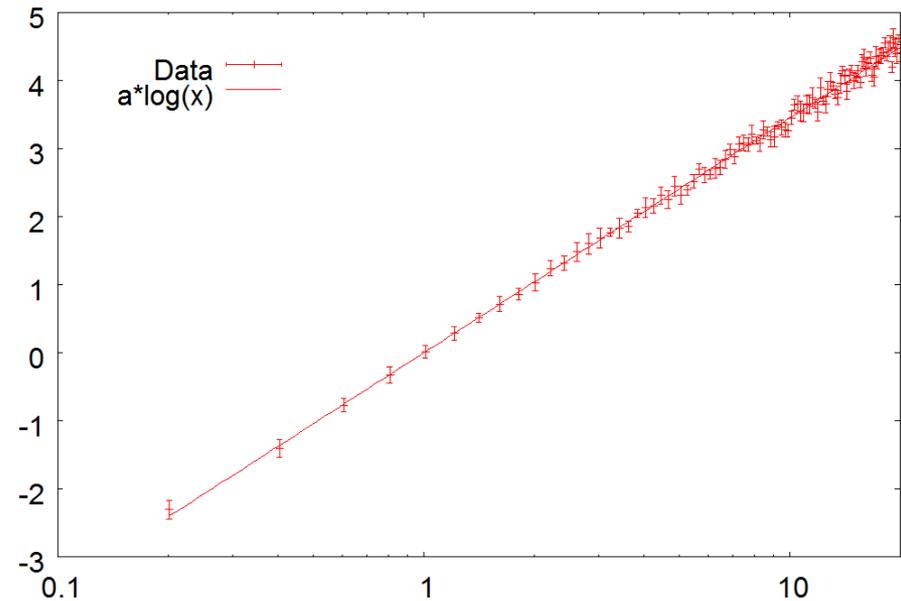
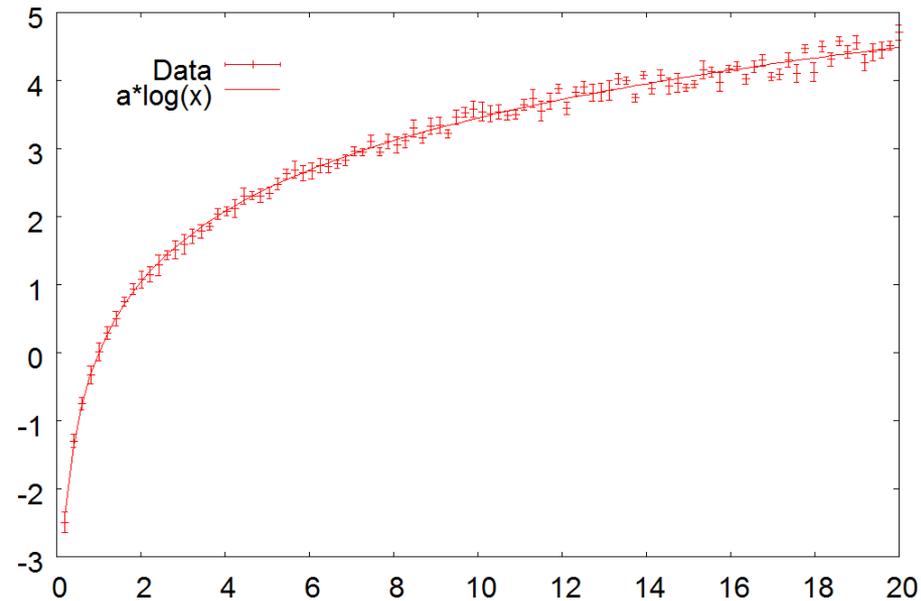
# Logarithmische Skalen

halb-logarithmisch: x-Achse logarithmisch und y-Achse linear

$$y(x) = a * \log(x)$$

$$x' = \log(x)$$

$$y(x) = a * x'$$



# Logarithmische Skalen

doppel-logarithmisch: x-Achse logarithmisch und y-Achse logarithmisch

$$y(x) = a * x^p$$

$$\log y(x) = \log(a) + p x' \quad (x' = \log(x))$$

